

SVEUČILIŠTE U ZAGREBU
FILOZOFSKI FAKULTET
ODSJEK ZA INFORMACIJSKE I KOMUNIKACIJSKE ZNANOSTI
AKADEMSKA GODINA 2016/2017.

Marija Haviđić

Poslovna inteligencija

Diplomski rad

Mentor: dr. sc. Vedran Juričić

Zagreb, 2017.

Sadržaj

SAŽETAK.....	4
1. UVOD	5
2. ZNANJE KAO RESURS	7
2.1. Definiranje znanja	7
2.2. Kategorije znanja	8
2.3. Upravljanje znanjem	10
3. POSLOVNA INTELIGENCIJA.....	18
3.1. Koncept poslovne inteligencije	20
3.2. Razvoj poslovne inteligencije	22
3.3. Sustav poslovne inteligencije.....	22
3.3.1.Faze razvoja informacijskog sustava.....	24
4. PRIMJENA POSLOVNE INTELIGENCIJE	28
4.1. Skladištenje podataka (engl. <i>Data Warehouse</i>)	28
4.1.1.Osnovne funkcije skladišta podataka	31
4.1.2.Uloga skladišta podataka.....	31
4.1.3.Struktura skladišta podataka	32
4.1.4.Implementacija skladišta podataka u poslovni subjekt	34
4.2. Rudarenje podataka (engl. <i>Data Mining</i>).....	34
4.2.1.Priprema podataka za <i>Data Mining</i>	35
4.2.2.Metode rudarenja podataka	37
4.2.3. Područja primjene alata za rudarenje podataka.....	39
4.3. Analiza podataka	40
4.3.1.OLAP	40
4.3.2.SWOT	44
4.4.Planiranje i predviđanje budućih događaja	49

4.5.Smanjenje rizika	50
4.6.Donošenje odluka	50
 5. ZAKLJUČAK.....	51
 6. LITERATURA	52
6.1.Tiskani izvori.....	52
6.2.Internet izvori	52
6.3.Ostali izvori	54
6.4.Izvori slika.....	55

Diplomski rad: Poslovna inteligencija

SAŽETAK: Informacija određuje ljudsko djelovanje, stoga je bitno da je ona točna i potpuna te pravovremena. Informacije se prikupljaju, pohranjuju, analiziraju i distribuiraju uporabom informacijskih sustava. U kombinaciji s alatima i metodama poslovne inteligencije one postaju maksimalno iskoristive te mogu služiti za napredak poslovanja i povećanja profita. Cilj rada je pokazati mogućnosti poslovne inteligencije opisujući razne metode i tehnike o kojima je u današnjem informacijskom društvu sve više riječi. Iako oni imaju vrlo široki spektar uporabe, fokus će biti na poslovnom napretku poduzeća te ulozi informacijskih znanosti.

KLJUČNE RIJEČI: upravljanje znanjem, poslovna inteligencija

Master's Thesis: Business intelligence

ABSTRACT: The information defines human interacting, that is why it should be complete, accurate and prompt. The facts are being collected, archived, analyzed and distributed with the use of information systems. Together with the tools and methods of business intelligence, information can be very useful for business progress and profit increase. The main goal of this work is to show the different possibilities of business intelligence by describing the various methods and techniques, which are nowadays a top subject in the society of information technologies. Even though these have a wide spectrum of use, the focus will be on the business progress of a company and the big role of information sciences in this area.

KEY WORDS: knowledge management, business intelligence

1. UVOD

„Znanje je moć“ – već su ljudi davnih dana bili svjesne te činjenice, mnogo prije no što je engleski filozof Francis Bacon izjavio ovaj opće poznati citat ili Sun Tzua svojim vođama dao važne savjete o taktikama na bojnome polju te o korištenju varki i lukavština opisanim u knjizi Umijeće ratovanja. Kroz cijelu povijest je onaj tko „zna“ uvijek bio u prednosti pred onim koji „ne zna“.

I u današnjem se svijetu često govori o ulozi znanja pri rješavanju problema, prije svega gospodarskim. Ali i u mikroekonomskom kontekstu često se znanje navodi pri rješavanju pitanja opstanka poduzeća, a i u kontekstu širenja poslovanja. Istovremeno je sve češće govor o tome kako je naše društvo na prijelazu iz informacijskog u društvo znanja, budući da je došlo da značajnih strukturalnih promjena u razvoju ekonomije, te glavni resursi više nisu materijalna dobra (industrijsko društvo), a bit znanja više nije povećanje produktivnosti ljudskoga rada. Danas ponuda znatno premašuje potražnju, pa je teže no ikad prije boriti se s konkurencijom. Traženi su proizvodi koji proizlaze iz znanja, a kako bi se isti proizveli bitno je da zaposlenici barataju znanjem. Stoga se pojavila potreba za raznim disciplinama koje se bave znanjem, kao što su upravljanje znanjem (engl. *Knowledge Management*) ili poslovna inteligencija (engl. *Business Intelligence*).

Prvobitni cilj ovog rada bio je prikaz poslovne inteligencije iz perspektive informacijske znanosti. Većina literature napisana je iz perspektive ekonomista ili informatičara. Tijekom pisanja postalo mi je jasno kako je nemoguće držati se isključivo perspektive infomatologa, budući da je područje poslovne inteligencije veoma interdisciplinarno, stoga se konstantno isprepliću prije svega ekonomija, informatika i informacijske znanosti, te razne slične znanosti koje su također interdisciplinarne i čije je ograničavanje na jednu znanost gotovo nemoguće. Upravo stoga je glavni izazov ovog rada bila koncepcija rada, koju sam nekoliko puta mijenjala. Prethodno objašnjavanje i definiranje raznih pojmova, pojava, sustava i disciplina bilo je neophodno prije samog detaljnijeg ulaženja u temu poslovne inteligencije. Nadalje, iako je čest slučaj da razni autori razno tumače iste pojave,

ovaj je fenomen najizraženiji kod interdisciplinarnih znanosti, prije svega onih koji se bave umom ili inteligencijom.

Literatura vezana za ovu tematiku uglavnom je na engleskom jeziku, definicije su neujednačene, a prevođenjem na hrvatski jezik te pisanjem o toj znanosti javlja se još više mogućih poimanja. Tako se i sâm pojam *business intelligence* prevodi na razne načine, kao *poslovna inteligencija*, *poslovno-obavještajno djelovanje* i slično, ovisno o aspektu promatranja. Kao što je ranije navedeno, ova znanost vrlo je interdisciplinarna, stoga se glavni dio ovog rada sastoji od poglavlja: *znanje kao resurs*, *poslovna inteligencija* i *primjena poslovne inteligencije*.

Budući da se cijeli rad bavi inteligencijom i znanjem, poglavlje *znanje kao resurs* pobliže objašnjava kako znanje, koje je po prirodi apstraktno, predstavlja vrijednost i time postaje resurs. Navode se kategorije znanja i upravljanje znanjem, koje jest usko povezano s poslovnom inteligencijom. Slijedi poglavlje *poslovna inteligencija* koje obuhvaća razne definicije, povijesni pregled te koncepte, alate i sustave poslovne inteligencije. Poglavlje *primjena poslovne inteligencije* odvojeno je od prethodnog, budući se ovdje radi o konkretnoj primjeni, a ne o raznim definicijama i konceptima. Ono detaljnije prikazuje koncepte, alate i sustave poslovne inteligencije – kako funkcioniraju te gdje i kako se koriste.

2. ZNANJE KAO RESURS

Iako je znanje nematerijalno, ono čini intelektualni kapital tvrtke i predstavlja dio ukupne vrijednosti tvrtke, što ga čini resursom.

2.1. Definiranje znanja

Osim što mnoga poduzeća još uvijek ne koriste metode i alate za upravljanje znanjem, oni često također ne razlikuju sadržaje termina *podatak*, *informacija* i *znanje*.¹ Definicije ovih pojmova se razlikuju ovisno o području.

Podatak (engl. *data*) jest skup odvojenih, objektivnih činjenica o nekom događaju² - ukoliko je riječ o organizaciji znanja. U poslovnom svijetu podaci predstavljaju transakcije, događaje i sl., no podatak daje samo objektivni prikaz događaja. Kada neki podatak smjestimo u kontekst on postaje informacija. Dakle, obrađeni podatak čini informaciju, odnosno informacije su podaci obogaćeni smislom i važnošću.³

Informacija (engl. *information*) je zapravo podatak koji ima neko značenje. Informacije je moguće organizirati i zapisati u obliku podataka u informacijski sustav. Informacija je novo znanje koje primatelju donosi nove činjenice. Ona ima karakter novosti, otklanja neizvjesnost i služi kao podloga za odlučivanje.⁴ Iz informacija se dobiva znanje.

Definiranje **znanja** (engl. *knowledge*) poprilično je zahtjevno, budući da postoje mnogobrojne definicije, ali ne i jedna, općeprihvaćena definicija znanja.⁵ Prema jednoj od definicija, ono se definira kao *tekući miks iskustva, vrijednosti, informacija unutar nekog konteksta i stručnih spoznaja koji pruža okvir za procjenu i korištenje*

¹ Davenport, T. H., Prusak, L. (2000.), *Working knowledge: How Organizations Manage What They Know*, Boston: Harvard Business School Press, str. 1

² Davenport, T. H., Prusak, L. (2000.), *Working knowledge: How Organizations Manage What They Know*, Boston: Harvard Business School Press, str. 2

³ Davenport, T. H., Prusak, L. (2000.), *Working knowledge: How Organizations Manage What They Know*, Boston: Harvard Business School Press, str. 2

⁴ prof. dr. sc. Vladimir Mateljan, kolegij: Baze podataka, Filozofski fakultet u Zagrebu, Ak.god. 2012/2013

⁵ Meyer, B., Sugiyama, K. (2007.), *The concept of knowledge in KM: a dimensional model*, Journal of Knowledge Management, 11 (1), 17-35.

*novih iskustava i informacija.*⁶ U raznim definicijama navode se i pojmovi kao što su teoretsko ili praktično poznavanje predmeta, jezika i sl.⁷ ali i činjenica da se znanje gradi na temelju informacija koje su izvučene iz podataka.⁸ Upravo neujednačena definicija znanja te čovjekova fascinacija umom, znanjem i inteligencijom čini *znanje* čestim predmetom filozofskih rasprava. Znanje ovisi o kontekstu, što znači da nešto što je za jednu osobu znanje za drugu može biti samo informacija i obrnuto. Za lakše razumijevanje znanja, ono se kategorizira.

2.2. Kategorije znanja

Podjela u kategorije moguća je na više načina. Prema osnovnoj podjeli ono se dijeli na eksplicitno (engl. *explicit knowledge*) i tiho ili iskustveno znanje (engl. *tacit knowldege*).

EksPLICITNO znanje (objektivno, otvoreno, jasno ili deklarativno) pohranjeno je u knjigama ili drugim izvorima, u eksplicitnom obliku, a iskazuje se brojkama i slovima. Lako ga se dohvatiti čitanjem, obrazovanjem i slično, može ga se pohraniti te pretraživati uz pomoć informacijske tehnologije ili pak prenositi u obliku informacije.

ISKUSTVENO znanje (subjektivno, zatvoreno, osobno, prešutno, tiho, tacitno ili proceduralno) ima suprotne značajke, ono nije pohranjeno na nekom mediju, već u umu pojedinca i čine ga instinkt, iskustvo, obrazovanje, osobne vrijednosti, uvjerenje te vještine. Dakle, osobno znanje pojedinca. To znanje nije lako prenijeti, a ni bilježiti. Koristimo ga u gotovo svemu što radimo premda toga većinom nismo svjesni. Puno je vrijednije od eksplicitnog. Da bismo prenosili iskustveno znanje, moramo ga pretvoriti u eksplicitno. Korištenjem i modificiranjem tog znanja, ono postaje ponovno iskustveno.

Također postoji i **implicitno znanje** koje različiti autori različito tumače. Dok ga neki autori poistovjete sa iskustvenim znanjem, drugi navode kako je ono *znanje koje još*

⁶ Davenport, T. H., Prusak, L. (2000.), *Working knowledge: How Organizations Manage What They Know*, Boston: Harvard Business School Press, str. 10

⁷ Hrvatski jezični portal, URL: <http://hjp.znanje.hr/>

⁸ Fakultet organizacije i informatike (2017.) *Definicija znanja*, URL: <http://autopoiesis.foi.hr/wiki.php?name=KM+-+Tim+55&page=Definicija+znanja>

uvijek nije opipljivo, ali bi moglo biti eksplicitno (Koenig, 2012) ⁹. Dakle, kao međusloj između iskustvenog i eksplicitnog.

Pored osnovnih kategorija znanja, eksplicitnog i iskustvenog, navode se i druge kategorije znanja (čije se definicije ovisno o autorima razlikuju). Svaka kategorija ima svoju svrhu te svoje karakteristike.

Slijedi nekoliko kategorija sa popisa ¹⁰ kategorija znanja:

- Proceduralno znanje (engl. *Know How*) – znanje o tome kako nešto uraditi (procedure, proceduralna pravila, strategije, programi). Primjerice kako se primjenjuje određeni lijek.
- Deklarativno znanje (engl. *Know About*) – Činjenice o nekoj tematici (koncepti, objekti, činjenice). Primjerice koji je lijek prikladan za određenu bolest.

Budući da je znanje predmetom konstantnih preispitivanja i proučavanja, očekuje se kako će se popis specifičnih kategorija znanja s vremenom još proširiti. Drugi autori navode još i ove kategorije: ¹¹

- Metaznanja (engl. *Metaknowledge*) – znanje o znanju; koristi se u izboru znanja potrebnog za rješavanje problema iz neke domene (određenje problemskog prostora i shvaćanje potrebnog znanja).
- Ustaljena znanja (engl. *Common Sense*) – znanja koja se ne oslanjaju na strogo dokazane teorije, odnosno neprecizna i kompletna znanja; teško je unaprijed znati iskoristivost tih znanja; oslanjaju se dobrim dijelom na aproksimacije, intuiciju i analogije (uobičajene (zadane) pretpostavke, aproksimativni koncepti, generalne hijerarhije i analogije).

⁹ Europaska unija (2014.) *Upravljanje znanjem 2.0., Priručnik za poduzeća*, Program za cjeloživotno učenje (Lifelong Learning Programme), str. 12, https://bib.irb.hr/datoteka/740473.KM_2.0_HR.pdf

¹⁰ Alavi, M., Leidner, D. E. (2001.), *Review: Knowledge management and knowledge management systems: conceptual foundations and research issues*, MIS Quarterly, 25 (1), str.8, https://moodle.ufsc.br/pluginfile.php/950622/mod_resource/content/1/MISQ%202001%20Vol%2025%20No.%201%20page%20107%20Alavi%20Leidner.pdf

¹¹ Kolegij *Upravljanje znanjem*, Ekonomski fakultet u Osijeku, [http://www.efos.unios.hr/arhiva/dokumenti/UIR_7_UPRAVLJANJE%20ZNANJEM%](http://www.efos.unios.hr/arhiva/dokumenti/UIR_7_UPRAVLJANJE%20ZNANJEM%20)

Postavlja se pitanje: *Kako najbolje iskoristiti sve te kategorije znanja* (pogotovo one neobjektivne)? Upravo navedeni čimbenici znanja instinkt, iskustvo, obrazovanje, osobne vrijednosti, uvjerenje i vještine su karakteristike vrsnih menadžera pri donošenju odluka i upravo one mogu pružiti konkurentsku prednost. No koliko god bilo znanje nekog stručnjaka, ni on nema uvid u svaki bitan aspekt, stoga se koriste razni sustavi i alati.

Osim toga, općenito ne koristimo ukupni potencijal našeg znanja, pa otkrivanje i upravljanje te korištenje dobivenog znanja može dovesti do znatnog napretka pojedinca te poduzeća. Razne tehnike, sustavi i alati koriste se prije svega za opstanak na tržištu te za napredak poslovanja. Potrebno je, dakle, prepoznati kako je upravo znanje onaj resurs koji treba maksimalno iskoristiti, jer znanje daje glavnu prednost. No, treba znati kako upravljati ovako vrijednim resursom.

2.3. Upravljanje znanjem

Iako se oko definiranja pojma *upravljanje znanjem* (engl. *Knowledge Management, KM*) spominju problemi poput stava da se znanjem ne može upravljati, slijede dvije definicije:

- Sveiby navodi kako upravljanje znanjem uključuje *prepoznavanje i analiziranje raspoloživih i traženih resursa znanja i procesa... s ciljem ispunjavanja organizacijskih ciljeva*.¹²
- Leksikon menadžmenta definira upravljanje znanjem kao *niz međusobno povezanih aktivnosti organizacija i menadžmenta usmjerenih na strategiju i taktiku upravljanja ljudskim kapitalom, odnosno razvoj znanja, vještina i općenito kompetencija zaposlenih, know-howa, kroz obrazovanje i obuku, stjecanje radnog i profesionalnog iskustva i slično*.¹³

¹² Europaska unija (2014.) *Upravljanje znanjem 2.0., Priručnik za poduzeća*, Program za cjeloživotno učenje (Lifelong Learning Programme), str. 12, https://bib.irb.hr/datoteka/740473.KM_2.0_HR.pdf

¹³ Bahtijarević-Šiber, F., Sikavica P. (ur.) (2001.), *Leksikon menadžmenta*, Zagreb: Masmedia

Premda ne postoji konsenzus oko definicije upravljanja znanjem, cilj ove discipline je jasan: *osigurati znanja i stvoriti uvjete za inovacije, u svrhu kvalitetnijeg procesa donošenja odluka.*¹⁴ Ova se disciplina bavi otkrivanjem i primjenom znanja kako bi donositelj odluke (engl. *decision maker*) donio odluke radi boljeg poslovnog uspjeha. Sama disciplina sastoji se od tri elementa: ljudi, informacijske tehnologije i procesi, prikazano slikom 1.



Slika 1: Elementi KM-a¹⁵

Iako je upravo **ljudski faktor** onaj koji prouzroči najčešće pogreške, ljudi su ključan element upravljanja znanjem, jer je upravo nesavršen čovjek, sa znatno manjom memorijom i sposobnosti obrade podataka od računala, taj koji posjeduje razne kategorije znanja. Isprepliću se iskustva, vrijednosti i sl. Čovjek je donositelj odluke, a informacijske tehnologije olakšavaju donošenje odluke. Najbolji sustav ne vrijedi bez sposobnog donositelja odluke. Znanje zaposlenika predstavlja kapital u koji vrijedi ulagati i koji vrijedi razvijati.

U sljedeći element pod nazivom **informacijske tehnologije** ubrajaju se razni softveri i hardveri kao i sustavi i alati: od samog računala preko baza podataka, softverskih alata za prikupljanje ili obradu podataka do Interneta i sve tehnologije vezane uz njega kao što su taktike i alati za pretraživanje Interneta ili pak sustavi za vrednovanje te razni alati. Kratko rečeno – sva potrebna tehnologija koja daje na brzini i učinkovitosti te smanjuje prostor za pravljenje pogrešaka.

Ono što povezuje ljude i tehnologije su **proces**i koji uključuju znanje. Kod procesa se javlja situacija kako različiti autori navode različite procese, no one se svode na sljedeće kategorije:¹⁶

¹⁴ Wiig, K. M. (2004.), *People-focused knowledge management: how effective decision making leads to corporate success*, Oxford: Elsevier Butterworth-Heinemann

¹⁵ Izvor slike 1: Europaska unija (2014.) *Upravljanje znanjem 2.0., Priručnik za poduzeća*, Program za cjeloživotno učenje (Lifelong Learning Programme), str. 12, https://bib.irb.hr/datoteka/740473.KM_2.0_HR.pdf

- Identificiranje znanja (lociranje)
- Stvaranje znanja
- Pohranjivanje znanja
- Dijeljenje znanja
- Primjena znanja (implementacija)
- Očuvanje i ažuriranje znanja
- Primjena znanja

Prilikom identificiranja, stvaranja, pohranjivanja, dijeljenja, primjene i očuvanja znanja ono se pretvara iz oblika u oblik što je prikazano na slici 2.



Slika 2: Prikaz procesa pretvaranja znanja iz tacitnog u implicitno te u eksplicitno.¹⁷

Kategorija **identificiranje znanja** (lociranje znanja) bavi se utvrđivanjem statusa, mjesta i izvora znanja, kao i određivanjem stupnja toga znanja i moguće koristi za poduzeće. Znanje može biti pohranjeno interno (u nečijoj glavi) i eksterno (izvještaji, istraživanja, baze ...). Neki od alata za lociranje znanja su mape (mentalne mape, mape resursa znanja) i dijagrami.

Nakon lociranja slijedi proces **stvaranja znanja** koji obuhvaća pretvaranje tacitnog znanja u implicitno znanje uz pomoć raznih metoda kao što su upotreba analogija, analiza slučajeva, popis nedostataka, kreativno razmišljanje (engl. *brainstorming*) ili grupni rad.

¹⁶ Europaska unija (2014.) *Upravljanje znanjem 2.0., Priručnik za poduzeća*, Program za cjeloživotno učenje (Lifelong Learning Programme), str. 12, https://bib.irb.hr/datoteka/740473.KM_2.0_HR.pdf

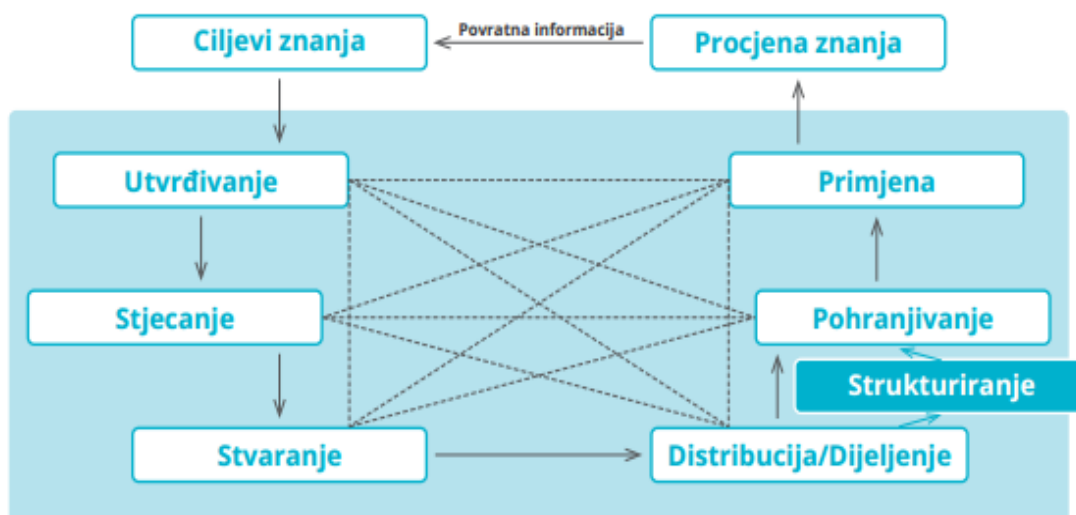
¹⁷ Izvor slike 2: vlasita izrada

U procesu **pohranjivanja znanja** implicitno se znanje pretvara u eksplicitno kako bi bilo u obliku pogodnom za pohranjivanje (npr. u neku bazu). Dobiveno znanje, koje je sada u eksplicitnom obliku, moguće je dijeliti i koristiti.

U ovom procesu **dijeljenja znanja**, prenosi se znanje s jedne osobe na drugu ili druge.

Svrha prethodnih procesa jest naravno **primjena znanja** (implementacija). Važna je mogućnost pristupa u pravo vrijeme, a ovaj proces ovisi ponajviše o ljudskom faktoru, o vještinama zaposlenika, prije svega donositeljima odluke. No uz njega potrebno je razvijati znanje drugih zaposlenika, jer ne može poslovanje ovisiti o samo jednoj osobi. Nadalje, treba izraditi učinkovite timove, jer je timski rad uvijek efikasniji, budući da ljudi različitog tacitnog znanja promatraju isti problem iz različitih aspekata. Zatim treba strateški razmišljati i u skladu s tim promišljanjima djelovati.

Tako dobiveno znanje potrebno je očuvati i nadopuniti što se naziva **očuvanje i ažuriranje znanja**. Ovaj element uključuje sve faktore vezane za proces odabira znanja koje se pohranjuje (na razne medije: tiskano, elektronički, audiovizualno i sl.) i nadopunjuje, ali i faktori kojima se procjenjuje koliko je to znanje vrijedno. Naposljetku dobiveno se **znanje primjenjuje**. Svi ti procesi su međusobno povezani, što prikazuje slika 3.



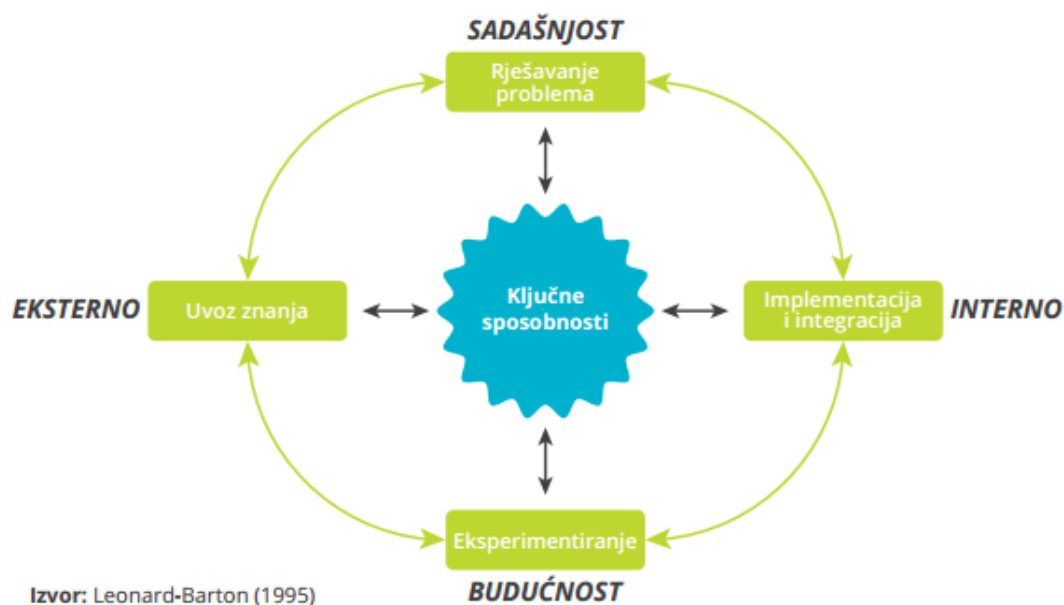
Slika 3: Temeljne komponente upravljanja znanjem koje pružaju G. Probs, S. Raub,¹⁸

¹⁸ Izvor slike 3: Europaska unija (2014.) *Upravljanje znanjem 2.0., Priručnik za poduzeća*, Program za cjeloživotno učenje (Lifelong Learning Programme), str. 55, https://bib.irb.hr/datoteka/740473.KM_2.0_HR.pdf

Strateško razmišljanje i upravljanje jest ključno, stoga treba uzeti u obzir i razne strategije upravljanja znanjem. One obuhvaćaju razne modele, a glavni su: ¹⁹

- resursni model,
- japanski model
- procesni model

Resursni model navodi kako je znanje osnovno sredstvo poduzeća te najvažniji resurs, a sposobnost upravljanje tim resursom opisana je knjigom *Izvori znanja* čiji je autor D. Leonard-Barton s Harvardske poslovne škole (eng. *Harvard Business School*). U njoj se navodi da izvori znanja mogu biti interni (u poduzeću) ili eksterni. Slika 4 prikazuje kako se eksterno znanje treba uvoziti, a interno implementirati. Ostale ključne sposobnosti su rješavanje problema u sadašnjosti te predviđanje budućih događaja te procjena potencijalnih situacija i rješavanje istih u budućnosti eksperimentiranjem.



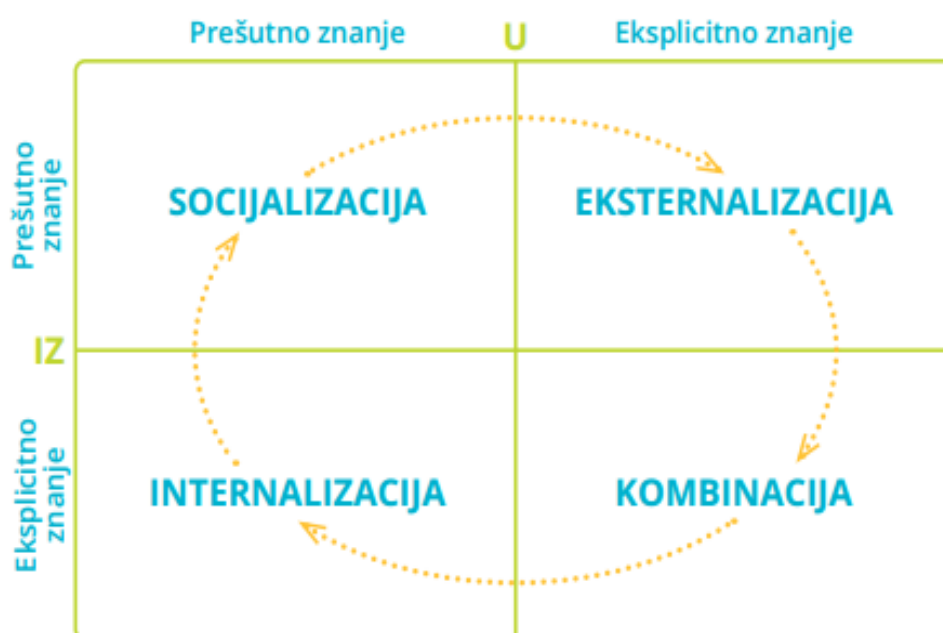
Slika 4: Resursni model upravljanje znanjem ²⁰

¹⁹ Europaska unija (2014.) *Upravljanje znanjem 2.0., Priručnik za poduzeća*, Program za cjeloživotno učenje (Lifelong Learning Programme), str. 48, https://bib.irb.hr/datoteka/740473.KM_2.0_HR.pdf

²⁰ Izvor slike 4: Europaska unija (2014.) *Upravljanje znanjem 2.0., Priručnik za poduzeća*, Program za cjeloživotno učenje (Lifelong Learning Programme), str. 48, https://bib.irb.hr/datoteka/740473.KM_2.0_HR.pdf

Glavna slabost ovog modela jest da se ne stvara novo znanje, već iskorištava postojeće, sustav nije inovativan.

Japanski model prikazuje tiho i formalno, odnosno skriveno i dostupno znanje. Upravljanje znanjem, prema japanskim istraživačima Nonaka i H. Takeuchi, temelji se na tzv. spirali kao ponavljajući ciklus četiriju procesa pretvorbe znanja (Sopińska, Wachowiak, 2006).²¹



Slika 5: Japanski model (spiralni) upravljanje znanjem²²

Proces stvaranja znanja obuhvaća prijelaz prešutnog (tihog) znanja u formalno (eksplicitno) znanje te ponovo eksplicitnog u tiho. Ovaj model ističe kako se eksplicitno nadopunjuje vještinama, osjećajima, vrijednosti i sl., prenosi te postaje eksplicitno, a zatim opet isto, to jest kako znanje poput spirale prijelazi iz oblika u oblik. Japanci naglašavaju kako znanje nije samo skup podataka i informacija, već ono obuhvaća i razne oblike skrivene u tihom znanju (osjećaji, iskustva) zato treba složeni problem rastaviti, podijeliti i u rješavanje uključiti zaposlenike (ne samo menadžere)

²¹ Europaska unija (2014.) *Upravljanje znanjem 2.0., Priručnik za poduzeća*, Program za cjeloživotno učenje (Lifelong Learning Programme), str. 49, https://bib.irb.hr/datoteka/740473.KM_2.0_HR.pdf

²² Izvor slike 5: Europaska unija (2014.) *Upravljanje znanjem 2.0., Priručnik za poduzeća*, Program za cjeloživotno učenje (Lifelong Learning Programme), str. 49, https://bib.irb.hr/datoteka/740473.KM_2.0_HR.pdf

budući da svaki individuum posjeduje različito tiho znanje koje može pomoći pri rješavanju problema.

Procesni model temelji se na praktičnim iskustvima u velikim poduzećima za konzalting, a upravljanje znanjem jest skup procesa koji omogućuju stvaranje, širenje i korištenje znanja u cilju ostvarenja organizacijskih ciljeva.²³ Do ostvarenja organizacijskih ciljeva znanje prolazi kroz tri faze: stjecanje znanja, dijeljenje znanja i širenje znanja.



Slika 6. Faze u procesnom modelu²⁴

U prvom koraku, stjecanja ili stvaranja znanja, razvijaju se vještine zaposlenika (interno znanje) ili se koriste eksterni izvori radi nedostatka internih resursa znanja. Istraživanja o praksi stjecanja znanja otkrila su kako zaposlenike treba ohrabriti u razvijanju vještina i usvajanju znanja. Stečeno znanje se zatim dijeli i širi na što je više moguće sudionika, jer se znanje tako obogaćuje tj. povećava se razina osobnog u intelektualnog kapitala. Za dijeljenje valja koristiti razne informacijske tehnologije, od grupnog rada do baza podataka. Naposljetku zaposlenici, koje treba poticati na inovativnost, iz dobivenog znanja donose odluke (u skladu s kompetencijama).

Upravljanje znanjem usko je povezano s poslovnom inteligencijom, a granice su često nejasne. Herschel i Jones navode kako je upravljanje znanjem zapravo dio poslovne inteligencije. Naglasak pritom stavljaju na ljudsku komponentu.

²³ Europaska unija (2014.) *Upravljanje znanjem 2.0., Priručnik za poduzeća*, Program za cjeloživotno učenje (Lifelong Learning Programme), str. 49, https://bib.irb.hr/datoteka/740473.KM_2.0_HR.pdf

²⁴ Izvor slike 6: Europaska unija (2014.) *Upravljanje znanjem 2.0., Priručnik za poduzeća*, Program za cjeloživotno učenje (Lifelong Learning Programme), str. 49, https://bb.irb.hr/datoteka/740473.KM_2.0_HR.pdf

- *Upravljanje znanjem je poslovna inteligencija usmjerena prema unutra, između zaposlenih se prenosi inteligencija kako efikasno izvesti razne funkcije potrebne kako bi organizacija funkcionirala.*²⁵

Isti autori definiraju poslovnu inteligenciju kao

- *set tehnologija koje prikupljaju i analiziraju podatke kako bi poboljšale proces donošenja odluka, pri čemu se za potrebe poslovne inteligencije ta inteligencija često definira kao pronalazak i objašnjavanje skrivenih, prisutnih i bitnih konteksta u ogromnim količinama poslovnih i ekonomskih podataka.*²⁶

Poslovna je inteligencija, dakle, usmjerena prema tehnologijama, metodama i alatima koje se koriste, kako bi se upravljalo znanjem.

²⁵ Herschel, R. T., Jones, N. E. (2005.), Knowledge management and business intelligence: the importance of integration, Journal of Knowledge Management, 9 (4), str. 46

²⁶ Herschel, R. T., Jones, N. E. (2005.), Knowledge management and business intelligence: the importance of integration, Journal of Knowledge Management, 9 (4), str. 46

3. POSLOVNA INTELIGENCIJA

Živimo u doba informacija, stoga je glavno sredstvo uspješnog poslovanja pravilna informacija u pravo vrijeme. Samo poduzeća koja uspješno barataju informacijama te pretvaraju informacije u znanje i koriste isto, mogu opstati na tržištu. Upravo time se bavi poslovna inteligencija.

Sam termin u hrvatskoj literaturi nema jasno određen prijevod. Stoga će se u ovom radu ponekad nalaziti pojam *poslovna inteligencija*, a ponekad *business intelligence* ili *poslovno-obavještajno djelovanje*, ovisno o citiranom autoru i aspektu promatranja, iako pojedini autori navode kako se ne radi o sinonimima, dok neki navode da je poslovna inteligencija prijevod pojma *business intelligence*. Ni definicija nije jednoznačno određena. U uporabi je više desetaka definicija koje se razlikuju od autora do autora te s obzirom na polazište s kojega se navedeni pojam promatra.

Promatrano s makroaspekta:

- *Razmatrano s makroaspekta, poslovna je inteligencija složena, agregirana kategorija koja se stvara sustavnim, ali unaprijed naciljanim prikupljanjem podataka o makroekonomskim kretanjima u određenoj geopolitičkoj sredini, njihovim organiziranim i strukturiranim bilježenjem odnosno pohranjivanjem, pretraživanjem te logičkom i računalnom obradom poradi otkrivanja makroekonomskih trendova ili tendencija te predviđanja i prognoziranja procesa i događaja u makroekonomskim sustavima i njihovih budućih stanja.*²⁷

Slijede definicije koje promatraju poslovnu inteligenciju s mikroaspekta:

- *Inteligencija podiže informacije u organizaciji na višu razinu. Podaci i informacije su stvari. Inteligencija je organska materija; izvedena iz informacija, ona pridonosi stvaranju takvog stanja organizacije koje se može nazvati kolektivnom inteligencijom. Inteligencija proizlazi iz punog razumijevanja informacija, ranije poduzetih akcija i postojećih mogućnosti,*

²⁷ Panian, Ž., Klepac G. (2003.) Poslovna inteligencija, Zagreb: Massmedia, str. 21

*odnosno opcija. Jednom posijana, inteligencija će se sama širiti širom organizacije. Kritička masa pojedinaca koji imaju dobar uvid i dijele slične stavove i poslovnim procesima postaje u takvim uvjetima vrlo moćna snaga.*²⁸

- *Poslovna se inteligencija najvećima koristi za karakterizaciju onih pristupa poslovanju koji imaju za cilj pretvorbu željenih rezultata u stvarnost. Prominentne svjetske kompanije shvaćaju poslovnu inteligenciju kao sredstvo čijom se primjenom njihovim zaposlenicima otvaraju mogućnosti za donošenje što boljih odluka, u što kraćem vremenu, uz visok stupanj pouzdanosti.*²⁹

Bilandžićeva definicija navodi odnos poslovne inteligencije prema informacijskim znanostima:

- *Business intelligence podrazumijeva proces prikupljanja podataka i informacija iz unutarnje i vanjske poslovne okoline te njihovo pretvaranje u poslovna znanja na temelju kojih se donose poslovne odluke.*³⁰

Dok ova općenita definicija navodi koje metodologije i alate koristi poslovna inteligencija:

- *Business intelligence (BI, poslovna inteligencija) je pojam koji objedinjuje skup metodologija (Data Warehousing, Data Mining, OLAP) i softverskih alata kojima se omogućuje korištenje podataka iz različitih skladišta podataka (Data Warehouse) i njihovo pretvaranje u informaciju potrebnu za donošenje poslovnih odluka.*³¹

Zajedničko svim tim definicija jeste kako je poslovna inteligencija proces planiranog prikupljanja i analize podataka te pretvorba istih u znanje kako bi to znanje pomoglo pri planiranju budućih akcija i donošenju odluka radi unaprijeđenja poslovanja te rasta i razvitaka poslovanja. Primjenom odgovarajućih logičko-računarskih metoda,

²⁸ Panian, Ž., Klepac G. (2003.) Poslovna inteligencija, Zagreb: Massmedia, str. 21

²⁹ Panian, Ž., Klepac G. (2003.) Poslovna inteligencija, Zagreb: Massmedia, str. 21

³⁰ Bilandžić, M. et al., (2012.), *Business Intelligence u hrvatskom gospodarstvu*, hrcak.srce.hr/file/126155

³¹ *Općenito o Business Intelligence sustavima*, <http://www.mit-software.hr/usluge/bi/bi1/>

poslovna se inteligencija može izvesti iz operativnih podataka. Da bismo upravljali tim podacima potrebno je razvijanje jedinstvenog sustava prilagođenog pojedinoj tvrtci. Uspješne tvrtke analiziraju i utvrđuju one elemente koji bitno pridonose stvaranju konkurentske prednosti kao i one koji osiguravaju dugoročni rast i razvitak tvrtke i na temelju istih kreiraju poslovne strategije. Parametri koji se koriste u kreiranju strategija su kapital, pristup distribucijskim kanalima, diferencijacija proizvoda, ekonomija veličine i znanje.³² Najveću konkurentsku prednost daju upravo znanje i vještine zaposlenika, no znanju se do sada nije dalo veliku pozornost. Da bi se upravljalo znanjem i stvorila tvrtka koja stalno uči, trebaju postojati preduvjeti i infrastruktura. Upravo ovdje se javlja važnost informacijskih i komunikacijskih tehnologija. Njihov razvoj omogućava uspješnu uspostavu infrastrukture.

Sustav poslovne inteligencije danas predstavlja srž tvrtke. On daje cjelovit i jednoznačan prikaz podataka, izvučenih iz raznoraznih izvora te se uz pomoć njega vrši analiza i planiranje događaja u tvrtki. On ne postoji kao gotov proizvod već samo kao tehnološka platforma različitih proizvođača za ugrađivanje znanja. Sustavi poslovne inteligencije su iznimno pregledni, informacije su lako dostupne i omogućen je cjeloviti pogled na cijelu tvrtku tako da svaki korisnik sustava može doći upravo do te informacije koja mu je potrebna.

3.1. Koncept poslovne inteligencije

Glavna namjena poslovne inteligencije jest generiranje što kvalitetnijih informacija (ne stvaranje novih). Generiraju se što kvalitetnije informacije potrebne pri donošenju daljnjih poslovnih odluka. Poslovnu inteligenciju čine poslovanje tvrtke, informacijski sustav i menadžment (Slika 7).

³² Znanje kao konkurentska prednost (2001.), <http://www.skladistenje.com/znanje-kao-konkurentska-prednost/>



Slika 7: *Elementi poslovne inteligencije*³³

Ovi su elementi u međuzavisnosti. Da bi se uvela poslovna inteligencija trebaju se stvoriti tehnički preduvjeti (informacijski sustav), no i poslovanje kao takvo treba biti makar održivo, a tek onda može određeni menadžer, odnosno donositelj odluke, donijeti odluku anticipirajući buduće procese i događaje. Djeluje se, dakle, proaktivno. Kako bi odluke bile kvalitetne, informacije moraju biti potpune, točne i dostupne u pravo vrijeme.

Poduzeća uvođe poslovnu inteligenciju jer je tržišna konkurencija sve jača, a distribucijski kanali i ponuda robe te usluga sve razvijeniji. Kako ne bi samo opstali na tržištu već i rasli, koriste alate poslovne inteligencije. Oni omogućuju uspješniju komunikaciju unutar poduzeća te s kupcima, dobavljačima i partnerima, ali i bolji uvid u ogromnu količinu kompleksnih podataka koja vrlo često biva neiskorištena.

³³ Izvor slike 7: Dukić, B. (2013/2014), Kolegij: Baze podataka, Sveučilište Josipa Juraja Strossmayera u Osijeku, Alati poslovne inteligencije, http://www.mathos.unios.hr/~dskrobar/BP_MATHOS_Alati.pdf

3.2. Razvoj poslovne inteligencije

Sam pojam *business intelligence* prvi je uveo Howard Dresner 1989. godine kako bi kategorizirao koncepte i metode koji pomažu u lakšem donošenju poslovnih odluka.³⁴

Intenzivan razvoj počeo je kada su poduzeća automatizirala svoje poslovne procese tj. kada su počela koristiti transakcijske sustave kao generatore velikih količina podataka što je dovelo do tzv. *eksplozije podataka*. Do ogromnih količina podataka nije bilo moguće doći niti njima upravljati. Zahvaljujući velikom potencijalu tih ogromnih količina podataka pokrenute su različite metode pretvaranja sirovih podataka u informacije. Objedinjenje i obrađene podatke daju se na raspolaganje menadžmentu radi daljnje analize te pomoći u procesu odlučivanja.

3.3. Sustav poslovne inteligencije

Sustav poslovne inteligencije ne postoji kao gotov proizvod, već proizvođači nude tehnološke platforme i znanje za implementaciju sustava koji se kreira individualno obzirom na potrebe poduzeća. Ono što je zajedničko svim sustavima jest osnovna infrastruktura potrebna za izradu takvih sustava. Osnovne komponente su procesi, alati (više o alatima u poglavlju 4. *Primjena poslovne inteligencije*) i drugi sustavi.

ETL procesi služe za ekstrakciju (engl. *extract*) i preoblikovanje (engl. *transform*) te unos (engl. *load*) podataka iz jednog ili više sustava u skladište podataka (engl. *Data Warehouse*). Prvo se podaci unificiraju (daje im se jedinstveni prikaz u jedinstvenom formatu), što je neophodno za daljnju obradu. Čišćenje podataka ima za cilj ukloniti podatke koji su nastali kao greška u radu informacijskih sustava.

Alati za upite (engl. *Query Tools*) predstavljaju programske pakete koji omogućuju korisnicima postavljanje upita o matricama ili detaljima u podacima. Uz pomoć njih moguće je izraditi nekoliko scenarija i predviđati budućnost da bi tvrtka bila

³⁴ Journal of Knowledge Management, Economics and Information Technology,
http://www.scientificpapers.org/wp-content/files/1102_Business_intelligence.pdf

pripremljena na svaku moguću situaciju na tržištu. Vizualizacijski alati (engl. *Dashboard/Scorecard tools*) su alati koji vizualno prikazuju tražen upit. Alati za rudarenje podataka (engl. *Data Mining tools*) omogućuju automatsko pretraživanje karakterističnih matrica ili korelacija među podacima. Softver za multidimenzijske analize, poznat pod skraćenicom OLAP (engl. *Online Analytical Processing*) omogućuje korisnicima pogled u podatke s različitih aspekata i dimenzija tj. istovremeno se može promatrati podatke veći broj filtera, koji se u stručnoj terminologiji nazivaju dimenzijama.

Osim od procesa i alata, sustav poslovne inteligencije sastoji se i od drugih sustava, primjerice od:

- Sustavi za podršku odlučivanju (engl. *Decision Support Systems*)
- Sustavi upravljanja znanjem (engl. *Knowledge Management Systems*)
- Sustavi za online analitičku obradu (engl. *Online Analytical Processing*)
- Sustavi za rudarenje podataka (engl. *Data Mining*)
- Sustavi za upravljanje informacijama (engl. *Management Informations Systems*)
-



Slika 8: Informacijski sustavi kojima se koristi sustav poslovne inteligencije³⁵

³⁵ Izvor slike 8: Tomaš, A. (2014.) *Poslovna inteligencija – oblikovanje OLAP kocke na primjeru*, Završni rad, Fakultet organizacije i informatike, Varaždin, [https://bib.irb.hr/datoteka/718474.1-Anto Toma - Poslovna inteligencija oblikovanje OLAP kocke na primjeru.pdf](https://bib.irb.hr/datoteka/718474.1-Anto_Toma_-_Poslovna_inteligencija_oblikovanje_OLAP_kocke_na_primjeru.pdf)

Sustavi sa slike 8 nisu nužno podsustavi od kojih se sastoji određeni sustav poslovne inteligencije, već se svaki sustav poslovne inteligencije razvija individualno prema potrebama poduzeća. Stoga je bitno uključiti donositelje odluke u proces izrade sustava. Sustav mora biti zanimljiv i jednostavan za korištenje. Korisnike sustava (donositelje odluke) treba dobro ispitati o svrsi sustava, kako bi izrada bila usmjerena određenoj svrsi.

3.3.1. Faze razvoja informacijskog sustava

Svaki sustav prolazi kroz nekoliko faza razvoja. Ove se faze nazivaju još i životnim ciklusom informacijskog sustava te se načelno dijele na:

- | | | |
|--|---|---------------|
| 1. Strateško planiranje informacijskog sustava (strateški projekt) | } | projektiranje |
| 2. Analiza poslovnog sustava (glavni projekt) | | |
| 3. Oblikovanje informacijskog sustava (izvedbeni projekt) | | |
| 4. Izrada informacijskog sustava (proizvodnja) | } | izgradnja |
| 5. Uvođenje u rad (uvođenje) | | |
| 6. Održavanje i prilagođavanje informacijskog sustava (održavanje) | | |

Prema Pavliću, prve tri faze bave se zapravo logičkim oblikovanjem sustava (projektiranje), dok su ostale tri usmjerene fizičkim oblikovanjem (izgradnja).³⁶ Razvoj, odnosno projektiranje informacijskog sustava, usko je povezan s projektnim menadžmentom, budući da je izrada (bilo kojeg) sustava zapravo određeni projekt, ali i s informacijskim inženjeringom, on definira četiri osnovne faze razvoja: strateško planiranje, analizu poslovnog područja, dizajn sustava (oblikovanje) i konstrukciju (izradu) sustava. Obzirom na složenost i zadatke informacijskog sustava bira se metodologija za njegovu izgradnju. Svaki projekt prolazi kroz određene faze.

³⁶ Pavlić, M., (1996): Razvoj informacijskih sustava – projektiranje, praktična iskustva, metodologija, Znak, Zagreb. (<http://milepavlic.blogspot.hr/2013/11/kako-napraviti-informacijski-sustav.html>)

Slijedi detaljni prikaz faza prema metodologiji MIRIS (Metodologija za Razvoj Informacijskog Sustava) koja opisuje metode i upute za projektiranje i izradu informacijskog sustava.³⁷

- **Faza strateškog planiranja** veoma je bitna, budući da se radi o cjelokupnoj pripremi za određeni projekt. Prvo treba prikazati problem tako da se identificira korisnika i svrhu sustava (Tko će koristiti sustav? Što je njemu najbitnije?). Treba se pritom staviti u ulogu korisnika, a moguće je i upitati korisnika (koji često ni sam ne zna što zapravo hoće/treba) koje ga točno informacije zanimaju. To prikupljanje poslovnih potreba i korisničkih zahtjeva dijeli se na konceptualni, logički i fizički dizajn. Za konceptualni dizajn prikupljaju se zahtjevi korisnika različitim metodama: intervju, promatranje korisnika prilikom rada, proučavanje postojećih sustava, prototipizacija, ankete i sl. U fazi logičkog dizajna detaljno se opisuje sustav/projekt prema organizacijskim i strukturnim kriterijima, no i prema odnosima pojedinih dijelova kao i izgledu sučelja. Fizički dizajn opisuje programersku implementaciju logičkog dizajna komponenta, servisa i korištenih tehnologija. Zahtjevi se rastavljaju na najmanje jedinice funkcionalnost kako bi se moglo procijeniti potrebno vrijeme i resursi za izradu.

Ukoliko već postoji neki informacijski sustav u poduzeću, tada se u ovoj fazi identificiraju nedostaci postojećeg sustava. Zatim slijedi izrada vizije konačnog proizvoda te prikaz ciljeva prilikom dizajna, treba dakle ustanoviti stupanj automatizacije sustava, odlučiti se o tehnologijama, platformi i slično, ali i provjeriti tehničke mogućnosti i izraditi funkcionalne specifikacije. Nadalje je potrebna izrada cjelokupnog plana odnosno glavnog plana projekta uzevši u obzir moguće aspekte o kojima ovisi izgradnja sustava (financijski plan, vremenski plan, raspoložive resurse, i sl). Također je bitno sastaviti radnu skupinu, voditi računa o vještinama i znanjima te skupine kao i o raspodijeli ovlasti i posla, treba dakle izraditi organizacijsku strukturu. Bitno je jasno odrediti cilj, no pritom imati na umu kako će korisnik gledati na sustav, dakle gledati iz perspektive korisnika. Ukratko, u ovoj se fazi vrši detaljno planiranje i definiranje, sastavljanje i poduka tima, izrađuju teoretski koraci

³⁷ Pavlič, M., (1996): Razvoj informacijskih sustava – projektiranje, praktična iskustva, metodologija, Znak, Zagreb. (<http://milepavlic.blogspot.hr/2013/11/kako-napraviti-informacijski-sustav.html>)

pri izradi, sastavlja popis potrebne dokumentacije, određuje koji su podsustavi potrebni, što je prioritet pri izradi, koja je infrastruktura potrebna ... dakle čitav niz neizostavnih koraka, a rezultat ove faze jest *definicija poslovnog sustava*.³⁸

- Drugu fazu, **analizu poslovnog sustava**, Pavlić naziva glavnim projektom, no ova se faza naziva također i planiranje projekta³⁹ te obuhvaća kompletnu izradu glavnog plana projekta. U ovoj se fazi izrađuje projektni zadatak te se vrši analiza pojedinih struktura, procesa i modela, a rezultat analize nazivamo poslovnim modelom. Poslovni model jest konceptualni model informacijskog sustava. On prikazuje sustav pomoću osnovnih koncepata neovisnih o kasnijoj implementaciji. Dvije su osnovne komponente takvog konceptualnog poslovnog modela: model okoliša i model ponašanja. Prema modelu okoliša određuju se granice informacijskog sustava kao i okoliša sustava, dakle ono što sustav sadržava, a to je *područje interesa ili domena informacijskog sustava*. Modelom ponašanja opisuje se kako se informacijski sustav „ponaša“ obzirom na svaki korak koji se odvija u njemu. Dakle, glavni plan se rastavlja na pojedine zadatke kako bi analizirali procese, probleme i poboljšanja te mogući rizici i rješenja, a listu potencijalnih poteškoća valja rangirati, kako bi se znalo djelovati. Ovaj dio je veoma bitan i zbog toga što se na temelju pojedinih komponenta te mogućih problema izrađuje funkcionalna specifikacija projekta koja predstavlja ugovor između naručitelja i proizvođača aplikacije. Ukoliko ovaj dio nije dobro izrađen, može doći do velikih poteškoća, primjerice financijskih ali i pravnih.
- **Oblikovanje informacijskog sustava** jest treća faza i ona predstavlja izvedbeni projekt. U ovoj se fazi modeli podataka prevode u shemu baze podataka, odnosno definira se arhitektura informacijskog sustava te se projektiraju operacije nad shemama.

³⁸ Pavlić, M. (2013.), *Kako napraviti informacijski sustav*, URL: <http://milepavlic.blogspot.hr/2013/11/kako-napraviti-informacijski-sustav.html>

³⁹ Pavlina, K. (2015.) Kolegij: Projektiranje informacijskih sustava, Filozofski fakultet u Zagrebu

- **Izrada informacijskog sustava** je faza proizvodnje tj. razvoja sustava, odnosno aplikacije. Izrađuju se pojedini dijelovi predviđeni u konceptu, razvija ih se i testira. Također se vrši testiranje i popravljaju što je potrebno popraviti. O svemu treba voditi zapisnik. Na kraju ove faze korisniku se prezentira napravljeno te mu se, nakon što se uklone eventualne primjedbe, isporučuje narudžba.
- U petoj fazi, **uvođenje u rad**, gotov se sustav instalira kod korisnika te ga se podučava korištenju.
- Zadnja faza jest **održavanje i prilagođavanje informacijskog sustava**. Kao što je jasno iz naziva, sustav se održava, prati se jesu li potrebna poboljšanja, ako da, onda se to zapisuje kako bi se sam sustav nadogradio (engl. *update*).

4. PRIMJENA POSLOVNE INTELIGENCIJE

Problem informacijskog doba nije dostupnost podataka, već njihovo optimalno iskorištavanje radi ekstrakcije kvalitetnih informacija koje pomažu u procesima donošenja poslovnih odluka. Upravo za to se primjenjuje poslovna inteligencija.

Informacije koje svakodnevno stižu treba pohraniti i organizirati tako da budu lako dostupne te iskoristive za predviđanje i planiranje te naposljetku i donošenje odluka. Za to se koriste različite metode, alati, sustavi i koncepti koji pomažu smanjiti rizik pri donošenju odluka na temelju otkrivenog znanja. *Koncept otkrivanja znanja, među ostalim, ima zadatak smanjivanja rizika i neizvjesnosti u procesima donošenja odluke. Naslućivanje tržišnih mogućnosti i tržišnih niša, kao i učinke donošenja strateških odluka koje će imati dugoročne posljedice na budućnost poduzeća, moguće je analizirati i projicirati pomoću poslovne inteligencije.*⁴⁰ No, treba imati na umu da je čovjek glavni čimbenik, on donosi odluke na temelju računalnih analiza, a čovjek ima nešto što računalo nema, a to je intuicija koja je svojstvena vrhunskim menadžerima.

4.1. Skladištenje podataka (engl. *Data Warehouse*)

Svakodnevno prikupljamo velike količine podataka iz različitih izvora, aktivno i pasivno. Svakodnevna komunikacija (razgovori, narudžbe, kupnje, mailovi i sl.), ali i proaktivno traženje određenih informacija te „bombardiranje“ raznim (na prvi pogled) nebitnim informacijama iz okoline nosi more bitnih i nebitnih informacija sa sobom. Čak 93% raspoloživih podataka nije moguće iskoristiti (istraživanje IBM-a), stoga valja prikupljene podatke skladištiti na valjan način kako bi ih se maksimalno moglo iskoristiti.

Jedan od razloga gubitka velike količine informacija jest činjenica kako postoji nekoliko aplikacija za različite aspekte svakodnevnog poslovanja (nabava, narudžba, računovodstvo ...). Svaka od tih aplikacija koristi vlastite resurse pa tako i vlastitu bazu podataka, a upravo zbog toga što nisu integrirane i što se ne mogu koristiti zajedno otežan je pristup podacima i mnoge informacije ostaju skrivene. Drugi

⁴⁰ Klepac, G., Mršić, L. (2006.) *Poslovna inteligencija kroz poslovne slučajeve*, Zagreb: lider TIM press

problem je taj što korisnik za rad u bazama podataka treba vladati SQL-om, a nije realno očekivati da svaki krajnji korisnik baze zna postaviti pravi upit. Stoga se probudila ideja o skladištenju podataka. Informacije raštrkane na razne baze zasnovane na relacijskom modelu služe za operativno vođenje poslovanja, (jer prikazuju ažurno, stvarno stanje poslovnog sustava). Međutim, za donošenje pravilnih poslovnih odluka potreban je drugačiji model baza podataka koji je zasnovan na mogućnosti složenih analiza i time daje uvid i u vremenski redoslijed zbivanja poslovnih događaja. Taj se model naziva skladištem podataka.


- *Skladištenje podataka predstavlja proces izuzimanja podataka iz postojećih (transakcijskih) sustava te transformiranje istih u organizirane informacije koje se mogu koristiti za donošenje odluka.*⁴¹

Osnovnu komponentu skladišta podataka (engl. *Data Warehouse*) čini baza podataka. U bazama su podaci upisani u tablice koje su u relacijama, tj. operativnim bazama podataka. Dobivene podatke iz takvih baza nije moguće pretraživati u stvarnom vremenu, jer su vrlo veliki i složeni, a izvješća su u dvodimenzionalnom obliku i na velikom broju stranica te predstavljaju selektirano prepisivanje podatke iz baze. Takve klasične baze podataka ne daju uvid u vremenski redoslijed zbivanja poslovnih događaja, stoga ne pokazuju stvarno stanje poslovnog sustava. Zato se koriste skladišta podataka. Ona sadrže podatke iz različitih izvora (iz operativne baze podataka, npr. povijesne o poslovanju poduzeća) i podatke iz vanjskog okruženja (podaci o konkurenciji, demografski trendovi, prodajni trendovi i sl.), a dizajnirane su tako da omogućavaju pretraživanje podataka, online analitičku obradu, izvješćivanje i podržavanje procesa donošenja odluka. U njima se pohranjuju već skupljeni i analizirani podatci koji su organizirani u skupove, a temelj su za sustave potpore odlučivanja.

- *Skladište podataka predstavlja subjektno usmjeren (subject-oriented), integrirani (integrated), vezan na vrijeme (time-variant) i sadržajno*

⁴¹ Dobrinić, D. (2011.) Marketing i baze podataka, Varaždin: Fakultet organizacije i informatike, str. 21

*nepromjenjiv (non-volatile) skup podataka, a krajnji cilj mu je potpora menadžmentu pri donošenju odluka.*⁴²



Slika 9: Slika prikazuje definiciju Skladišta podataka prema Billu Inmonu⁴³

Subjektna usmjerenost znači da skladište daje točno određene informacije u okviru funkcionalnih područja (npr. u okviru prodaje, nabave...), dok operativne baze podataka daju informacije o tekućim operacijama (npr. obrade narudžbi, isporuka i sl.). Integriranost se odnosi na to da se podaci skupljaju iz različitih izvora i pohranjuju u istom formatu, oni su konzistentni i prikazani na dosljedan način. Svi podaci u skladištu podataka vezani su uz vrijeme, što znači da se identificiraju uz određeni vremenski period, dok podaci u bazama nemaju vremensku komponentu, već prikazuju samo aktualno stanje. Podaci zapisani u skladištu ne mijenjaju se nakon unosa – sadržajna nepromjenjivost – već se promjene bilježe u vremenskom razdoblju.

⁴² "Data Warehousing - Definition", <http://www.1keydata.com/datawarehousing/data-warehouse-definition.html>

⁴³ Izvor slike 9: Mastek (2017): *Definition of a Data Warehouse*, slide 20, <https://www.slideshare.net/pcherukumalla/date-warehousing-concepts>

4.1.1. Osnovne funkcije skladišta podataka

Primjenom skladišta podataka rasterećuju se operativne baze podataka složenih upita vezanih uz analizu podataka i vremensku komponentu, stoga dolazi do unaprjeđenja operativnih funkcija transakcijskih baza, lakše kontrole i restrukturiranja podataka te shodno time i učinkovitijeg poslovanja poduzeća.

Osnovna funkcija skladišta podataka je skupljanje podataka i stvaranje logički integriranih i predmetno usmjerenih informacija, a samo skladište treba oblikovati na jednostavan i brzo prilagodljiv način, tako bi se osiguralo stalno pronalaženje novih informacija ovisno o zahtjevima poslovnog okruženja, budući da se zahtjevi mogu brzo mijenjati.

4.1.2. Uloga skladišta podataka

Najjednostavnije rečeno, uloga skladišta podataka jest otkriti one informacije iz operativnih baza podataka koje su ostale neotkrivene te „pomiješati“ ih s informacijama iz vanjskih izvora kao što su podaci o konkurenciji, demografski trendovi, prodajni trendovi i sl. Skladišta treba kontinuirano održavati, tj. nadopuniti i unaprijediti, ne zaboravljajući pri tome na svrhu skladišta (da ga se ne puni nerelevantnim informacijama). Da bi skladište podataka moglo ispuniti cilj i svrhu svog postojanja, mora ispuniti nekoliko preduvjeta:

- **Pristup**
 - Osigurati pristup svim zaposlenicima tvrtke na vodećim pozicijama
 - Brz, jednostavan i pouzdan pristup
- **Velika količina detaljnih podataka**
 - Sve poslovne transakcije relevantne za donošenje poslovnih odluka moraju biti evidentirane u skladištu podataka, a uneseni podaci trebaju biti konzistentni
- **Kontinuirano ažuriranje podataka**
 - Po mogućnosti u stvarnom vremenu; nakon što se neki poslovni događaj odigrao ili odmah po završetku nekog procesa.
- **Stalna raspoloživost skladišta**

- Podaci moraju biti uvijek raspoloživi i oblikovani na način da mogu poslužiti svakoj svrsi koju nije uvijek moguće unaprijed predvidjeti
- Predvidljivost
 - Treba predvidjeti mogućnost izdvajanja i međusobnog povezivanja podataka u smislu dobivanja svih mjera i pokazatelja poslovanja u poduzeću (engl. *slice and dice*)
- Kvaliteta podataka
 - Podaci u skladištu koji se skupljaju iz različitih izvora, čiste se uz osiguranje kvalitete, jer loši ulazni podaci ne mogu davati dobre izlazne podatke
- Proširivost
 - Skladište mora biti proširivo da bi moglo slijediti strategiju proširenja poslovanja tvrtke
- Mjere zaštite
 - Mora udovoljavati odgovarajućim mjerama zaštite tajnosti osjetljivih podataka što se postiže provođenjem rigoroznih mjera čuvanja tajnosti

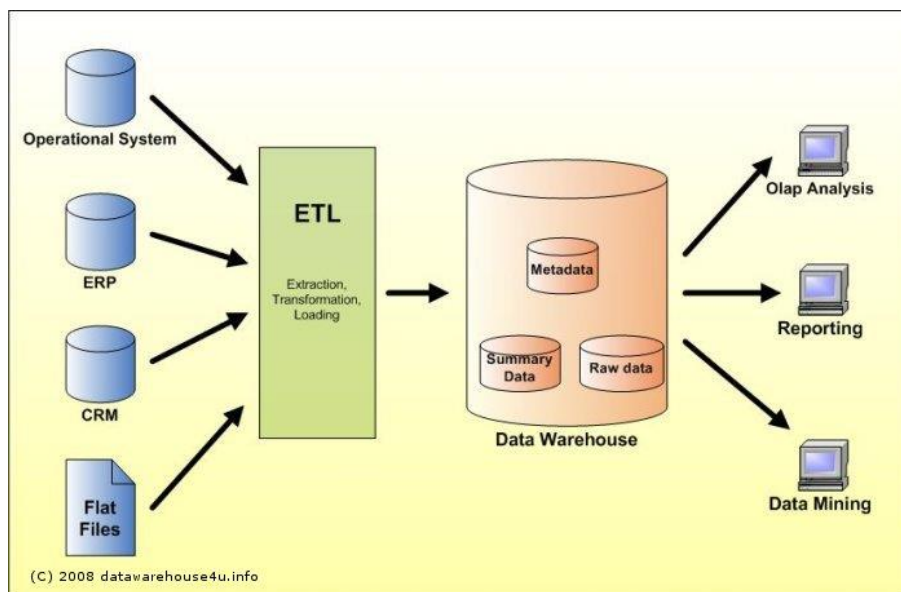
4.1.3. Struktura skladišta podataka

Strukturu skladišta čine dva dijela: *podaci* (osnovni i višedimenzionalni) i *mehanizmi za manipulacije tim podacima* (ETL-procesi, sustav upravljanja podacima, postupci analitičke obrade podataka i prezentacija podataka).

Skladište podataka sadrži podatke koji se koriste za vrlo složene analize poslovanja, te su optimizirana za masovno pretraživanje podataka i izvještavanje, te je najčešća aktivnost nad podacima samo čitanje. ⁴⁴

Kako bismo napunili skladište, podatke iz različitih izvora treba uz pomoć ETL procesa preseliti u bazu koja omogućuje analitičku obradu podataka tj. u skladište podataka, jer podaci su ovdje filtrirani i spremljeni u određenom formatu.

⁴⁴ Agilna poslovna inteligencija (2013.), članak, <https://sqlbicro.wordpress.com/tag/poslovna-inteligencija-2/>



Slika 10: *Infrastruktura skladišta podataka*⁴⁵

Na slici 10 prikazana je infrastruktura skladišta podataka. Podaci iz različitih izvora (baza, operacijskih sustava, ERP- ili CRM-sustava, raznih dokumenta, interneta i sl.) integriraju se uz pomoć ETL-procesa (engl. *Extract-Transform-Load*). Prije same ekstrakcije podatke treba reformatirati, usklađivati i čistiti tj. izvorne podatke zaprimljene iz različitih datoteka i baza podataka potrebno je unificirati odnosno prikazati u jedinstvenom formatu kako bi se moglo raditi s njima te kako bi se izbjegle eventualne greške. Upravo procesi integriranja podataka i organiziranje njihova sadržaja predstavljaju najopsežniji posao u aktivnostima skladištenja podataka. Prilikom izgradnje skladišta podataka za ETL-procese treba uložiti gotovo 70-80 % vremena.⁴⁶ Unificiranim podacima se zatim puni skladište. Iz tog skladišta sada je moguće izvući složene analize podataka. Podatke u skladištu moguće je analizirati na mnoge načine: kreiranje upita ili izvještaja, rudarenje podacima (engl. *Data mining*), korištenje OLAP-analize i sl. – upravo to upravljanje ubraja se u procese business intelligencea.

⁴⁵ Izvor slike 10: *Agilna poslovna inteligencija* (2013.), članak, <https://sqlbicro.wordpress.com/tag/poslovna-inteligencija-2/>

⁴⁶ Dobrinić, D. (2011.) *Marketing i baze podataka*, Varaždin: Fakultet organizacije i informatike, str. 23

4.1.4. Implementacija skladišta podataka u poslovni subjekt

Implementacija skladišta provodi se u sljedećim fazama:⁴⁷

1. Utvrđivanje zajedničkih elemenata i njihova unifikacija
2. Razvoj prve pilot-aplikacije
3. Aktiviranje novih spremišta i razvoj daljnjih aplikacija
4. Odvajanje različitih spremišta i razvoj centralnog

Uvođenje skladišta jest vremenski i financijski zahtjevan proces kojim se pospješuje poslovanje tvrtke, no uspostavom istog tek kreću obaveze, budući da skladište treba konstantno održavati, nadograditi i modificirati. Korištenjem skladišta javit će se također nove potrebe i zahtjevi, koje bi sustav trebao zadovoljiti. Dosadašnja istraživanja pokazala su da primjena skladišta donosi niz koristi, kao što su povećavanje efikasnosti odlučivanja, veća konkurentnost tvrtke i brži rast prihoda.

4.2. Rudarenje podataka (engl. *Data Mining*)

Pojam *rudarenje podataka* koristi se u širem značenju kao sinonim za proces otkrivanja znanja, a uže kao naziv koji se odnosi na fazu računalne obrade podataka u procesu otkrivanja znanja.⁴⁸ Rudarenjem podataka smatra se proces pronalaženja skrivenih informacija poput trendova, modela, zakonitosti i odnosa među podacima; odnosno, pretraživanjem velikih količina podataka i izvlačenjem relevantnih informacija. Primjenom alata za rudarenje podataka moguće je otkriti matrice ponašanja te predvidjeti buduće trendove i ponašanja, na temelju kojih se donose proaktivne odluke temeljene na znanju.

Kottler navodi kako

- *marketinški stručnjaci mogu iz mase podataka izvući korisne podatke o pojedincima, trendovima i segmentima.*⁴⁹

⁴⁷ Panian Ž., Klepac G., "Poslovna inteligencija", Masmedia, Zagreb, 2003., str. 101.

⁴⁸ Varga, M. (2004.), *Poslovna inteligencija: ciljevi i metode*, Ekonomski fakultet u Zagrebu, str.5, https://bib.irb.hr/datoteka/166465.Poslovna_inteligencija_HrOUG_2004.pdf

⁴⁹ Kottler, P., Keller, K. (2008.) *Upravljanje marketingom*, Zagreb: Mate, str. 144

Veoma sličnu definiciju daje i Dobrinić:

- *Rudarenje podacima je traženje (do sada) nepoznatih ili skrivenih uzoraka (modela, pravila) i veza unutar samih podataka, s ciljem pronalaska novih, dotad/dosad nepoznatih informacija koje bi se mogle iskoristiti prilikom donošenja odluka.*⁵⁰

Rudarenje se izvodi uz pomoć raznih metoda i tehnika.

- *Rudarenje podataka koristi sofisticirane statističke i matematičke tehnike poput klastera analize, automatskog otkrivanja interakcije, predviđajućeg modeliranja i neutralnih mreža.*⁵¹

4.2.1. Priprema podataka za *Data Mining*

Da bi *output* bio dobar, bitno je da i sam *input* sadrži kvalitetne podatke. Drugim riječima - dobar output ovisi o izvoru podataka te o samoj kvaliteti podataka. Poduzeća koja koriste poslovnu inteligenciju kao izvor uglavnom koriste skladišta podataka, što nije preduvjet za primjenu alata za rudarenje podataka, no iako su skladišta vrlo skupa rješenja, ona su također i najbolja rješenja. Kada se koriste drugi izvori koji mogu biti vrlo različiti – razne baze podataka, tekstualni dokumenti, Excel-dokumenti, webstranice i sl. – podaci koji mogu biti nekompletni i nekonzistentni, te oni trebaju proći kroz postupak čišćenja i pretprocesiranja, a istodobno treba voditi računa o planiranom cilju analize. Upravo analiza traje najduže (cca. 80% vremena), no potrebno je uložiti to vrijeme, jer primjena dobrih algoritama rudarenja podataka na loše pretprocesirane podatke rezultirat će lošim rezultatima. Stoga preprocesirani podaci trebaju proći kroz nekoliko postupaka, prema Panianu i Klepcu⁵² to su:

- Pronalaženje ekstremnih vrijednosti - Veoma je bitno uključiti u dijagnostiku podataka i ekstremne vrijednosti (engl. *Outliers*) unutar skupa podataka, budući da one mogu, ali ne moraju, upućivati na poučnu devijaciju, tj. prikazati nekakav

⁵⁰ Dobrinić, D. (2011.) Marketing i baze podataka, Varaždin: Fakultet organizacije i informatike, str. 23

⁵¹ Kottler, P., Keller, K. (2008.) *Upravljanje marketingom*, Zagreb: Mate, str. 144

⁵² Panian, Ž., Klepac, G. (2003.) *Poslovna inteligencija*, Massmedia, Zagreb

trend koji ne bismo niti primijetili bez analize. Nad njima se tada vrše dodatne analize, kako bi se odlučilo jesu li bitne ili ne.

- Dijagnostika nedostajućih vrijednosti i predviđanje nedostajućih vrijednosti - Ako neki podaci nedostaju, tada se njihova vrijednost predviđa, kako bi svi podaci bili konzistentni i potpuni radi daljnje analize.
- Povezivanje relacijskih ključeva iz različitih izvora podataka – kod različitih izvora je i relacijski ključ različit, tada se vrijednosti povezuju radi lakše kategorizacije.
- Postizanje jednoobraznosti (konzistentnosti) u podacima – svi podaci moraju biti konzistentni, ako u jednom izvoru piše ZG, a u drugom Zagreb te vrijednosti treba pretvoriti u isti podatak
- Uzorkovanje – kada se ne može zahvatiti cjelokupnu populaciju koristi se reprezentativni uzorak koji predstavlja cjelokupnu populaciju.
- Kategorizacija vrijednosti atributa – Atributima se dodaje određena vrijednost i time se stvaraju kategorije, npr. svi rođeni između 1980 i 1990 dobivaju istu vrijednost.
- Formiranje izvedenih atributa (engl. *Binning*) – vrlo slično kategorizaciji, no ovdje se formiraju nove kategorije koje obuhvaćaju vrijednosti sortiranog niza, dakle vrijednosti nije moguće direktno iščitati iz podataka
- Grupiranje - Primjenom ove metode velika količina podataka sažima se grupiranjem po određenim kriterijima
- Normiranje podataka – normiranje se najčešće odnosi na minimalne i maksimalne vrijednosti (npr. od 20 do 30 godina)

4.2.2. Metode rudarenja podataka

Rudarenjem podataka se iz velike mase podataka otkrivaju određene veze, pravilnosti i zakonitosti. Metode koje se najčešće koriste u procesu rudarenja podatka su:

- **Regresijska metoda**

Ova metoda koristi se kada se na temelju postojećih vrijednosti predviđaju ostale, npr. na temelju broja i dobi članova kućanstva predviđa se prodaja određenih artikala. No, često je teško predvidjeti vrijednost X samo na temelju vrijednosti Y , jer često mnogobrojni faktori utječu na vrijednost Y i tada treba primijeniti kompleksnije tehnike, kao što su stabla odlučivanja ili neuralne mreže.

- **Klasifikacijske metode**

Kao što ime kaže, vrši se klasifikacija tj. svrstavanje entiteta u grupu odnosno klasu koja se prethodno definira prema karakteristikama koje označavaju grupu što je ujedno i namjera ove metode. Ispitivanjem prethodno već klasificiranih podataka u neku bazu podataka prema predvidljivim obrascima kreiraju se klase.

- **Metode klasteriranja**

Metoda klasteriranja slična je klasifikacijskoj, jer se provodi grupiranje objekata sličnih karakteristika, no ciljevi metoda se razlikuju - ovdje je cilj da se znatno razlikuju jedna od druge, dok su članovi unutar grupa vrlo slični jedni drugima, kriteriji za razvrstavanje nisu prethodno definirani, već nastaju u postupku izrade klastera. Za izradu se koriste *algoritmi*, a najčešće su to *K-means algoritam* ili *hijerarhijsko klasteriranje*:

- *K-means algoritam* – Osnovna populacija proučavanja dijeli se na k segmenata, a svaki segment sadrži n sličnih elemenata. Sličnost se procjenjuje na temelju udaljenosti elementa od centralne vrijednosti (sličnije je bliže, različitije je dalje)
- *hijerarhijsko klasteriranje* – Od grupiranih objekata razrađuje se hijerarhijsko stablo (od dna prema vrhu Bottom-up ili od vrha prema

dnu Top-down). No ova se metoda koristi isključivo za numeričke vrijednosti (npr. dob) ili se vrijednosti pretvaraju u numeričke (npr. spol-m/ž u 0/1) te se uglavnom koristi za početnu segmentaciju tržišta.

- **Neuralne mreže**

Ova je metoda inspirirana biološkim neuralnim mrežama te se uz ovu metodu mogu modelirati veliki i kompleksni problemi na koje može utjecati stotine varijabli, no ne postoji jedinstven model primjenjiv na sve vrste problema, a dobivene rezultate nije lako interpretirati (upravo zbog složenosti i velikih broja varijabli). Neuralne mreže mogu istovremeno provoditi mnoge kalkulacije te se koriste za prognoziranje trendova i predviđanje na temelju povijesnih podataka.

- **Stabla odlučivanja**

Kod stabla odlučivanja klasificiraju se atributi u odnosu na ciljnu varijablu, a rezultate je lako interpretirati. Osnovne komponente predstavlja korijen stabla, a čvorovi, grane i lišće su varijable. Razlikujemo klasifikacijska stabla od regresijskih. Klasifikacijska svrstavaju primjere u kategorije (klase) i koriste za predviđanje kategoričkih (bezuovjetnih) varijabli, dok se regresijska stabla koriste za predviđanja kontinuiranih varijabli.

- **Metode za analizu veza (asocijacija)**

Za analizu veza karakterističan je opisni pristup istraživanju podataka koji može pomoći pri identifikaciji odnosa među vrijednostima u bazi podataka (npr. analiza tržišne košarice). Cilj ove metode jest otkrivanje zakonitosti, konkretno za tržišnu košaricu – koji se artikli kupuju zajedno uz pomoć asocijacija (primjer: četkica za zube i pasta za zube), time se može povećati prodaja. Osim analize koji se proizvod prodaje u kombinaciji s drugim, doznaje se uz pomoć modela za analizu veza i gdje se prodaje neki proizvod više, npr. u poslovnici 1 prodaje se više integralnog kruha nego bijelog, stoga će se dobavljati više integralnog kruha u poslovnici 1. Ali kupci koji kupuju integralni kruh vjerojatno će kupiti integralno brašno, pa se mogu brašno, odnosno slične proizvode također u većem broju posložiti u poslovnici 1.

4.2.3. Područja primjene alata za rudarenje podataka

Da bismo uspješno provodili rudarenje podataka, potrebno je:

- pravilno integrirano skladište podataka
- dobro poznavanje i razumijevanje procesa poslovanja

Također je bitno imati predznanje o statistici te je primjena alata najkorisnija tamo gdje stalno pristiže mnoštvo novih podataka za obradu. Primjena je vrlo široka, koristi se u raznim branšama kao što su proizvodnja ili telekomunikacije, no također i u bankarstvu, financijama, osiguranju te u vele- i maloprodaji ⁵³ u svrhu zadržavanja korisnika neke usluge, otkrivanje navika pri kupnji, optimalizacije kupovine, otkrivanje prijevara s kreditnim karticama i sl. Tako recimo tvrtka *Hrvatski telekom d.d.* ima odjel koji se zove *Retention* kojemu je zadatak zadržati korisnike. Uz pomoć rudarenja podataka te raznih tehnika i metoda pretražuju se sve informacije o korisniku – koju je uslugu prije imao, koju trenutno ima, zašto je nezadovoljan, što ponuditi da bude zadovoljan, a firma istovremeno na dobitku. Možemo zamisliti da su baze podataka prostor na kojemu se ostavljaju tragovi o poslovnom odnosu (kupci, klijenti, korisnici). Svaka interakcija se bilježi: poziv, e-mail, kupnja, ponuda, transakcija. Upravo ti tragovi predstavljaju pouzdane informacije o poslovnim partnerima. Da bi se znalo što ponuditi, treba predvidjeti nekoliko scenarija i u skladu s predviđenim složiti odgovarajuću proceduru. Upravo dubinskom analizom tj. rudarenjem podataka otkrivaju se uzroci i relacije u pohranjenim podacima i predviđa buduće ponašanje.

Da bismo otkrili određeno znanje, potrebno je proći nekoliko koraka, a to su:

- selekcija podataka,
- pročišćavanje podataka,
- redukcija i projekcija podataka,
- određivanje najprikladnije metode rudarenja podataka,
- ispravna interpretacija rezultata

U korak selekcije ubraja se odabir ciljne skupine podataka nad kojima će se provesti postupak otkrivanja znanja. U fazi pročišćavanja dohvate se podaci s raznih računala

⁵³ Žalac, N., "Rudarenje podataka i njihovo pretvaranje u znanje", Hrvatska gospodarska revija, Zagreb, 2000., br. 6, str. 96

i baza, zatim se čiste (isti naziv i sl.) te upare. Dalje se podaci iz transakcijskih baza podataka i iz drugih izvora pretvaraju u višedimenzijske baze, a u sljedećem se koraku odabire najpogodnija metoda rudarenja podataka (klasifikacija, klasteriranje, analiza tržišne košarice ...). Naposljetku treba ispravno interpretirati dobivene rezultate obrade te tako otkriti znanje.

4.3. Analiza podataka

Sve nabrojene metode i tehnike koriste se radi obrade podataka tj. analize na temelju koje se donose odluke. Razne metode i tehnike mogu se koristiti pri analizi, no oni mogu predstaviti i određene rezultate analize; ovisno o točki gledanja i vrsti istraživanja. U svakom slučaju sve metode i tehnike kao i njihovi rezultati koriste nam kako bismo iz hrpe podataka izvukli relevantne podatke i iskoristili ih najbolje moguće.


4.3.1. OLAP

OLAP znači online analitičko obrađivanje (engl. *Online Analytical Processing*). Kao što je već u poglavlju 3.3.1. *Infrastruktura sustava poslovne inteligencije* spomenuto, OLAP je softver za multidimenzijske analize, dakle za istovremenu analizu iz različitih aspekata (kriterija) uz pomoć filtara.

OLAP se smatra "zametkom" koncepta poslovne inteligencije. Služi za izvođenje znanja iz podataka. Postavljanje pitanja i dobivanje odgovora se događa u vrlo kratkom roku "brzinom misli". Korisnik postavlja upit (postavlja filter) prema OLAP softveru, a OLAP podatke vadi iz skladišta podataka

Prema Panianu i Klepcu OLAP predstavlja konceptualni i intuitivni model koji će razumjeti svi korisnici, neovisno o stupnju obrazovanja čak iako nisu specijalizirani za obavljanje analitičkih poslova. OLAP nudi mogućnosti pregledavanja podataka kroz veći broj filtara i obavljanje brzih analiza što menadžerima omogućuje dobivanje odgovora na pitanja. OLAP alati imaju ogromnu sposobnost računanja i

teoretski je broj dimenzija neograničen, a najmanji broj dimenzija jest tri.⁵⁴ Primjer kocke vidljiv je na slici 11.



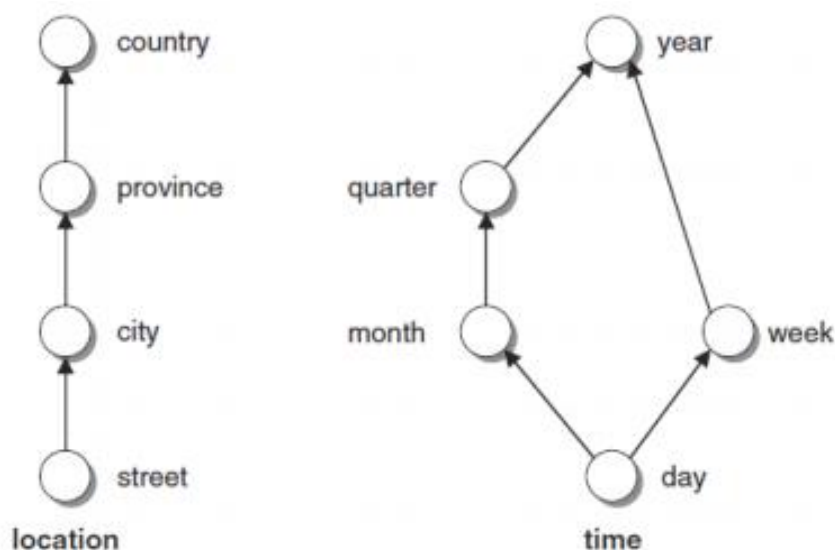
Slika 11: OLAP kocka⁵⁵

OLAP kocka dizajnira se upisivanjem informacija u tablice. Broj tablica odgovara broju dimenzija, a tablice zapravo čine šifranik budući da se u njima nalazite šifre i nazivi određenih dimenzija odnosno filtara podataka. Osnovu, dakle, čini znanje izrade baza podataka.

Korisnik vadi informacije uključivanjem određenih filtara (izvođenjem operacija) i tako kreira izvještaj. Vercellis navodi da su analize OLAP-kocke bazirane na hijerarhijama jer se tako kreiraju logički pogledi. Nadalje, da bi korisnik mogao pročitati informacije koje mu nudi OLAP, kreira se izvještaj nad kojim se mogu vršiti različite operacije. Ti se izvještaji baziraju na hijerarhijskom konceptu (slika 12). Ukoliko uzmemo za primjer dimenziju lokacija, imamo mogućnost analize za državu, županiju, općinu, grad itd. Spuštanjem kroz dimenzijske razine lokacije nazivamo jest *drill down* dok je dizanje *drill up*.


⁵⁴ Panian Ž, Klepac G (2003) *Poslovna inteligencija*. Zagreb: Masmedia, str. 236

⁵⁵ Izvor slike 11: Tomaš, A. (2014.) *Poslovna inteligencija – oblikovanje OLAP kocke na primjeru*, Završni rad, Fakultet organizacije i informatike, Varaždin, https://bib.irb.hr/datoteka/718474.1-Anto_Toma_-Poslovna_inteligencija_oblikovanje_OLAP_kocke_na_primjeru.pdf



Slika 12: Hijerarhija pojmova za dimenzije lokacije i vremena⁵⁶


Ostale operacije koje se mogu izvoditi su *Slice and Dice* te *Pivot*. Slice and Dice su operacije koje daju mogućnost horizontalnog (*dice*) i vertikalnog (*slice*) analiziranja podataka (slika 13).



Slika 13: Horizontalni i vertikalni prikaz OLAP-kocke⁵⁷

⁵⁶ Izvor slike 12: Vercellis, C. (2009) *Business Intelligence: Data Mining and Optimization for Decision Making*, John Wiley & Sons Ltd, str. 60

Operacija *Pivot* (slika 14) predstavlja rotaciju osi - tako se mijenjaju određene dimenzije, kako bi se stekao drugi pogled na multidimenzionalnu kocku.




Slika 14: Rotacije OLAP-kocke ⁵⁸

Određene situacije moguće je sagledati iz nekoliko perspektiva, odnosno dimenzija. OLAP-om je moguće odabrati dimenziju (ili više njih) te pogledati iz različitih dimenzija, dakle promatranje podataka na različite načine i interaktivno pretraživanje podataka. Slika 15 prikazuje OLAP kocku koja sadrži informacije o lokaciji, količini proizvoda te vremenskom periodu prodaje istog kao i pojedine dimenzije. Za određenog korisnika je određena dimenzija zanimljivija. Tako je primjerice menedžera financije bitna na što se najviše troši, dok je za lokacijskog menedžera bitna informacija gdje određeni proizvod najbolje prodaje. Također je moguće uključiti pogled na nekoliko dimenzija istovremeno.

⁵⁷ Izvor slike 13: Tomaš, A. (2014.) *Poslovna inteligencija – oblikovanje OLAP kocke na primjeru*, Završni rad, Fakultet organizacije i informatike, Varaždin, https://bib.irb.hr/datoteka/718474.1-Anto_Toma_-Poslovna_inteligencija_oblikovanje_OLAP_kocke_na_primjeru.pdf

⁵⁸ Izvor slike 14: Tomaš, A. (2014.) *Poslovna inteligencija – oblikovanje OLAP kocke na primjeru*, Završni rad, Fakultet organizacije i informatike, Varaždin, https://bib.irb.hr/datoteka/718474.1-Anto_Toma_-Poslovna_inteligencija_oblikovanje_OLAP_kocke_na_primjeru.pdf



Slika 15: Višedimenzionalni prikaz OLAP-kocke ⁵⁹

4.3.2. SWOT

SWOT je akronim za riječi *Strenghts*, *Weaknesses*, *Opportunities* i *Threats*. SWOT-analizom analiziraju se faktori koji utječu na poslovanje, a njih je moguće podijeliti na komponente prikazane slikom 16. Obzirom na zastupljenost određenih faktora, bira se strategija poslovanja.

⁵⁹ Izvor slike 15: Dukić, B. (2013/2014), Kolegij: Baze podataka, Sveučilište Josipa Juraja Strossmayera u Osijeku, Alati poslovne inteligencije, http://www.mathos.unios.hr/~dskrobar/BP_MATHOS_Alati.pdf



Slika 16: SWOT-Analiza ⁶⁰

Analiziraju se, dakle, kvalitete tj. snaga (*strenghts*) i slabosti (*weaknesses*) dok su vanjski faktori prilike (*opportunities*) i prijetnje (*threats*).

- Snaga (*strenghts*) - U kvalitetu poduzeća ubrajaju se kompetentnost, inovativna sposobnost, dobra tehnološka osnova i sl. Kvalitete predstavljaju nešto u čemu je poduzeće uspješno ili neko svojstvo koje pojačava njegovu konkurentnost.
- Slabosti (*weaknesses*) - Potencijalne slabosti predstavljaju određeni nedostaci ili neuspjesi te uvjet koji uzrokuje nepovoljan položaj na tržištu, a to su nejasna strategija razvoja i ciljeva poslovanja, nedostatak stručnosti, loš poslovni ugled itd.
- Prilike (*opportunities*) – prilike su događaji koji otvaraju prostor za nove poslovne mogućnosti, npr. uspavanost konkurenta, visoka stopa rasta tržišta i sl.
- Prijetnje (*threats*) – prijetnje su negativni događaji koji mogu ugroziti poslovanje poduzeća, recimo ulazak nadmoćne konkurencije na tržište, sporija stopa rasta tržišta i dr. ⁶¹

⁶⁰ Izvor slike 16: Market Research SWOT, <http://www.discoveryresearchgroup.com/swot>

⁶¹ Bilandžić, M. (2008.) Poslovno obavještajno djelovanje - Business intelligence u praksi, Zagreb: AGM, str.100

Analizom elemenata vrši se vrednovanje resursnih sposobnosti i nedostataka, tržišnih prilika i vanjskih prijetnji te se odabire poslovna strategija. SWOT-analiza provodi se u tri koraka (Thompson, Strickland, Gamble, 2005.):

1. identifikacijom (kvaliteta, nedostataka, prilika i prijetnji)
2. zaključivanjem (u kojoj od situacija se nalazi poduzeće)
3. provođenjem strategija (za unaprijeđenje poduzeća)

Nakon identifikacije svih čimbenika i razvrstavanjem istih u kategorije S-W-O i T valja navesti (barem) tri ključna čimbenika za svaki element (Primjerice: Snaga - proizvod je nov, nema ga još na tržištu; Nedostatak - kako zainteresirati kupce za nešto nepoznato?) Zatim slijedi stavljanje čimbenika i elementa u međudnose te razmatranje međusobnog djelovanja jednog na drugog: S-W, S-O, S-T, W-O, W-T, O-T. Nadalje treba analizirati mogućnosti pretvaranja snaga u slabosti i obrnuto, te prilika u prijetnje i obrnuto kao i ocjenjivanje intenziteta utjecaja svakog pojedinog čimbenika za sve elemente SWOT analize, ocjenom u rasponu od 0 do 10 (0 - nema utjecaja, 10 - vrlo visoki intenzitet utjecaja) i izračunati prosječni intenzitet za svaki element SWOT analize. Nakon detaljne analize svih ključnih prijetnji i prilika valja izraditi SWOT-tablicu (slika 17) koja sadrži sve do sad opisane elemente: po 3 ključna čimbenika za snagu, prijetnju, priliku i mogućnost, ocjena pojedinačnog intenziteta utjecaja i prosječan intenzitet za svaki element SWOT analize.

Br.	Elementi SWOT analize	Intenzitet utjecaja
	SNAGE (S)	
1.		
2.		
3.		
	Prosječni intenzitet utjecaja:	
	SLABOSTI (W)	
1.		
2.		
3.		
	Prosječni intenzitet utjecaja:	
	PRILIKE (O)	
1.		
2.		
3.		
	Prosječni intenzitet utjecaja:	
	PRIJETNJE (T)	
1.		
2.		
3.		
	Prosječni intenzitet utjecaja:	

SLIKA 17: SWOT-tablica⁶²

Zatim valja izraditi novu tablicu koja prikazuje umnoške prosječnih ocjena intenziteta Snaga-Prilika, Snaga-Prijetnji, Slabosti-Prilika i Slabosti-Prijetnje (Slika 18)


	Snage x Prilike	Snage x Prijetnje	Slabosti x Prilike	Slabosti x Prijetnje
Umnožak	(pr. 55,04)	(pr. 79,12)	(pr. 30,08)	(pr. 43,24)

SLIKA 18: Umnošci prosječnih ocjena intenziteta S-O, S-T, S-O i S-W⁶³

Iz tih dviju tablica sada je moguće izraditi grafikon poligona strategije (slika 19).

⁶² Izvor slike 17: Zdravstveno veleučilište Zagreb (2008), SWOT ANALIZA, <http://sharepoint.zvu.hr/katedre/318/Nastavni%20matrijali/SWOT-analiza,vježba.pdf>

⁶³ Izvor slike 18: Zdravstveno veleučilište Zagreb (2008), SWOT ANALIZA, <http://sharepoint.zvu.hr/katedre/318/Nastavni%20matrijali/SWOT-analiza,vježba.pdf>



SLIKA 19: Poligon strategije ⁶⁴

Na temelju svih prethodnih koraka moguće je naposljetku izrada matrice o strateškim preporukama (slika 20).

	SNAGE (S)	SLABOSTI (W)
PRILIKE (O)	MAXI-MAXI Strategija - SO maksimirati snage da bi se maksimizirale prilike u okolini	MINI- MAXI Strategija - WO minimizirati slabosti da bi se maksimizirale prilike u okolini
PRIJETNJE (T)	MAXI-MINI Strategija - ST maksimirati snage da bi se minimizirale prijetnje u okolini	MINI-MINI Strategija - WT minimizirati slabosti da bi se minimizirale prijetnje u okolini

SLIKA 20: Matrica strateških preporuka strategije ⁶⁵

⁶⁴ Izvor slike 19: Zdravstveno veleučilište Zagreb (2008), SWOT ANALIZA, <http://sharepoint.zvu.hr/katedre/318/Nastavni%20matrijali/SWOT-analiza,vježba.pdf>

⁶⁵ Izvor slike 20: Zdravstveno veleučilište Zagreb (2008), SWOT ANALIZA, <http://sharepoint.zvu.hr/katedre/318/Nastavni%20matrijali/SWOT-analiza,vježba.pdf>

Naposljetku se izabere strategija koju valja primijeniti. Razlikujemo strategije SO, WO, ST i WT. Ukoliko su kvalitete na visokoj razini te istovremeno postoji potencijalna prigoda, tada se primjenjuje SO-strategija koja je potencijalno najuspješnija. Ukoliko su uz slabosti prisutne i prilike, tada je glavni cilj savladati te slabosti te nastojati koristiti povoljne prilike (WO-strategija). Ako postoje unutarnje kvalitete te istovremeno vanjske opasnosti, tada je cilj maksimalizacija unutarnje snage i minimalizacija vanjske opasnosti (ST-strategija). Ukoliko su unutarnje slabosti jake i istovremeno postoje vanjske opasnosti, tada se primjenjuje WT-strategija koja nameće potrebu uvođenja raznih restrikcija ili likvidaciju poslovnog sustava.

4.4. Planiranje i predviđanje budućih događaja

Poslovna se inteligencija koristi za povećanje učinkovitosti, primjerice u marketingu – ako kupci ne reagiraju dobro na određeni proizvod tada se pokušava otkriti razlog i prilagoditi proizvod tržišnim potrebama. Koristi se i u operativi - bolnice uz pomoć poslovne inteligencije utvrde optimalan broj pojedinih djelatnika za vrijeme najvećih gužvi, dok pozivni centri predviđaju broj djelatnika i linija obzirom na pretpostavljenu količinu poziva i prosječnom trajanju u određenom danu odnosno u određeno doba dana. Dostavljači i prijevoznici planiraju optimalnu rutu i metode dostave, a trgovci uz pomoć BI mogu provjeriti stanje u skladištu i shodno tome napraviti narudžbe. Ukratko, primjena poslovne inteligencije vrlo je opširna, gotovo ne postoji područje u kojemu njezini alati i metode ne pomažu boljem poslovanju te ona predstavlja temelj prilikom izrade raznih aplikacija i programa.

4.5. Smanjenje rizika

Za smanjenje rizika prilikom donošenja odluka može se koristiti sustav za podršku odlučivanju (engl. *Decision Support Systems*), jer njegov je cilj smanjenje nesigurnosti kod donošenja poslovnih odluka. Ovi sustavi već prilikom prikupljanja informacija identificiraju i rješavaju probleme. Sustav pribavlja, čisti, vrednuje i prezentira relevantne podatke donositelju odluke, odnosno izgrađuje računalni model kojim se moguća rješenja problema evaluiraju i time pronalazi najbolje rješenje, i to u realnom vremenu. Koristi li se ovaj sustav pravilno, najviše koristi donosi kada je tržište nestabilno te tvrtka posluje u uvjetima nesigurnosti. Ovaj je sustav jedan od najsloženijih informacijskih sustava, jer donosi rješenja koja se temelje na slabo- i nestrukturiranim problemima. Također ga se koristi prilikom odlučivanja o rutinskim problemima. Ovaj se sustav služi analitičkim metodama, pa su donesene odluke racionalne.

4.6. Donošenje odluka

Naposljetku sve metode i tehnike opisane ovim radom služe za donošenje kvalitetnih odluka. Kao što sam nekoliko puta navela u radu, ljudski faktor je onaj odlučujući. Najbolje informacije ne znače ništa ako se čovjek ne zna služiti njima. Navedene metode i tehnike služe lakšem i bržem donošenju odluka.

5. ZAKLJUČAK

Kroz detaljan teoretski prikaz vidljivo je kako poslovna inteligencija ima široku primjenu, ona se prožima kroz sve funkcije i sve industrije. No, učinkovita je samo ako je se učinkovito primjeni. Prije svega, potrebno je dobro baratati podacima i različitim vrstama znanja. Zatim je moguća (i poželjna) primjena različitih alata i metoda kako bi se maksimalno iskoristilo postojeće znanje koje često zna biti skriveno. Premda je implementacija sustava poslovne inteligencije vrlo složena i skupa, a i potrebni su stručnjaci za korištenje i procjenu analiziranih podataka, za opstanak na tržištu te rast i razvitak poduzeća primjena poslovne inteligencije je itekako bitna, ako ne i neophodna.

Ali, i najbolji sustavi su bezvrijedni bez adekvatnog stručnjaka koji ih zna primijeniti – znati što tražiti, kako odrediti parametre za izradu sustava, kako koristiti dobivene rezultate i sl. Stručnjaci, dakle ljudski faktor, jest onaj ključan. No, kako je poslovna inteligencija veoma složena i interdisciplinarna, teško je joj je odrediti područje odnosno s kojeg područja dolaze ti stručnjaci – ekonomisti, informatolozi, informatičari? I nakon pisanja ovog rada i dalje nisam sigurna u odgovor. Sigurno je da stručnjak za poslovnu inteligenciju mora baratati (osnovnim) znanjem iz svih triju područja, no daljnja naobrazba ovisno o zahtjevima tržišta je apsolutna neizostavna. Također je sigurna činjenica kako bi stručni ekonomisti trebali usko surađivati s informatolozima i informatičarima kako bi rezultati bili što bolji. Poslovna inteligencija je jednostavno preširoko područje da bi se ograničilo samo na jednu znanost.

6. LITERATURA

6.1. Tiskani izvori

1. Bahtijarević-Šiber, F., Sikavica P. (ur.) (2001.), *Leksikon menedžmenta*, Zagreb: Masmedia
2. Bilandžić, M. (2008.) Poslovno obavještajno djelovanje - Business intelligence u praksi, Zagreb: AGM
3. Davenport, T. H., Prusak, L. (2000.), *Working knowledge: How Organizations Manage What They Know*, Boston: Harvard Business School Press
4. Dobrinić, D. (2011.) Marketing i baze podataka, Varaždin: Fakultet organizacije i informatike
5. Javorović, B., Bilandžić, M. (2007.) Poslovne informacije i business intelligence, Zagreb: Golden marketing-Tehnička knjiga
6. Klepac G., Mršić, L. (2006.) Poslovna inteligencija kroz poslovne slučajeve, Zagreb: TIM press
7. Kottler, P., Keller, K. (2008.) Upravljanje marketingom, Zagreb: Mate
8. Panian, Ž., Klepac G. (2003.) Poslovna inteligencija, Zagreb: Massmedia
9. Pavlić, M., (1996): Razvoj informacijskih sustava – projektiranje, praktična iskustva, metodologija, Znak, Zagreb
10. Potomac, MD (1999.) "Introduction to Data Mining and Knowledge Discovery", Two Crows Corporation
11. Vercellis, C. (2009) Business Intelligence: Data Mining and Optimization for Decision Making. John Wiley & Sons Ltd.
12. Wiig, K. M. (2004.), *People-focused knowledge management: how effective decision making leads to corporate success*, Oxford: Elsevier Butterworth-Heinemann, <https://books.google.hr>

6.2. Internet izvori

1. *Agilna poslovna inteligencija* (2013.), članak, <https://sqlbicro.wordpress.com/tag/poslovna-inteligencija-2/> (zadnji uvid 27.8.2017.)

2. Alavi, M., Leidner, D. E. (2001.), *Review: Knowledge management and knowledge management systems: Conceptual foundations and research issues*, MIS Quarterly, https://moodle.ufsc.br/pluginfile.php/950622/mod_resource/content/1/MISQ%202001%20Vol%2025%20No.%201%20page%20107%20Alavi%20Leidner.pdf (zadnji uvid 27.8.2017.)
3. Baranović, M., Zakošek, S. (2012.) *Baze podataka – predavanje*, Zagreb: Fakultet elektrotehnike i računarstva, https://www.fer.unizg.hr/_download/repository/Baze_podataka_Preddiplomski_Predavanja.pdf (zadnji uvid 25.5.2017.)
4. Bilandžić, M. et al., (2012.), *Business Intelligence u hrvatskom gospodarstvu*, hrcak.srce.hr/file/126155 (zadnji uvid 17.5.2017.)
5. Data Warehousing - Definition, <http://www.1keydata.com/datawarehousing/data-warehouse-definition.html> (zadnji uvid 27.8.2017.)
6. Definition of business intelligence: <http://searchdatamanagement.techtarget.com/definition/business-intelligence> (zadnji uvid 27.8.2017.)
7. Ekonomski fakultet u Osijeku, Kolegij: *Upravljanje znanjem*, http://www.efos.unios.hr/arhiva/dokumenti/UIR_7_UPRAVLJANJE%20ZNANJE M%20 (zadnji uvid 13.7.2017.)
8. Europaska unija (2014.) *Upravljanje znanjem 2.0., Priručnik za poduzeća, Program za cjeloživotno učenje (Lifelong Learning Programme)* https://bib.irb.hr/datoteka/740473.KM_2.0_HR.pdf (zadnji uvid 20.6.2017.)
9. Fakultet organizacije i informatike (2017.) *Definicija znanja*, <http://autopoiesis.foi.hr/wiki.php?name=KM++Tim+55&page=Definicija+znanja> (zadnji uvid 3.5.2017.)
10. Hrvatski jezični portal, <http://hjp.znanje.hr/> (zadnji uvid 3.5.2017.)
<http://sharepoint.zvu.hr/katedre/318/Nastavni%20matrijali/SWOT-analiza,vjezba.pdf> (zadnji uvid 27.8.2017.)
11. Journal of Knowledge Management, Economics and Information Technology, http://www.scientificpapers.org/wp-content/files/1102_Business_intelligence.pdf (zadnji uvid 3.5.2017.)
12. Lamza – Maronić, M., Glavaš, J., (2008.) *Poslovna inteligencija*, Osijek: Sveučilište Josipa Juraja Strossmayera u Osijeku, Ekonomski fakultet u Osijeku, <http://www.efos.unios.hr/arhiva/dokumenti/PRISTUPNI%20rad%20-%20PRIMJER.pdf> (zadnji uvid 3.7.2017.)
13. Mastek (2017): *Definition of a Data Warehouse*, <https://www.slideshare.net/pcherukumalla/date-warehousing-concepts> (zadnji uvid 27.8.2017.)

14. Općenito o Business Intelligence sustavima, <http://www.mit-software.hr/usluge/bi/bi1/> (zadnji uvid 27.8.2017.)
15. Pavlić, M. (2013.), *Kako napraviti informacijski sustav*, <http://milepavlic.blogspot.hr/2013/11/kako-napraviti-informacijski-sustav.html> (zadnji uvid 27.8.2017.)
16. Sveučilište Josipa Juraja Strossmayera u Osijeku (2013/2014), kolegij: Baze podataka, Alati poslovne inteligencije, URL: http://www.mathos.unios.hr/~dskrobar/BP_MATHOS_Alati.pdf (zadnji uvid 27.8.2017.)
17. Varga, M. (2004.), Poslovna inteligencija: ciljevi i metode, Ekonomski fakultet u Zagrebu, https://bib.irb.hr/datoteka/166465.Poslovna_inteligencija_HrOUG_2004.pdf (zadnji uvid 27.8.2017.)
18. Zdravstveno veleučilište Zagreb (2008.), SWOT ANALIZA,
19. *Znanje kao konkurentska prednost* (2001.), <http://www.skladistenje.com/znanje-kao-konkurentska-prednost/> (zadnji uvid 27.5.2017.)

6.3. Ostali izvori

1. Herschel, R. T., Jones, N. E. (2005.), *Knowledge management and business intelligence: the importance of integration*, Journal of Knowledge Management
2. Mateljan, V., (2012.) kolegij: *Baze podataka*, Filozofski fakultet u Zagrebu
3. Meyer, B., Sugiyama, K. (2007.), *The concept of knowledge in KM: a dimensional model*, Journal of Knowledge Management
4. Pavlina, K. (2015.) kolegij: *Projektiranje informacijskih sustava*, Filozofski fakultet u Zagrebu
5. Spremić, M., *Upravljanje znanjem od teoretskog modela do praktičnog pristupa*, Računovodstvo, revizija i financije, br. 9/2001
6. Žalac, N., *Rudarenje podataka i njihovo pretvaranje u znanje*, Hrvatska gospodarska revija, Zagreb, 2000., br. 6, str. 96

6.4. Izvori slika

1. Izvor slike 1: Europaska unija (2014.) *Upravljanje znanjem 2.0., Priručnik za poduzeća*, Program za cjeloživotno učenje (Lifelong Learning Programme), str. 12, https://bib.irb.hr/datoteka/740473.KM_2.0_HR.pdf
2. Izvor slike 2: vlasita izrada
3. Izvor slike 3: Europaska unija (2014.) *Upravljanje znanjem 2.0., Priručnik za poduzeća*, Program za cjeloživotno učenje (Lifelong Learning Programme), str. 55, https://bib.irb.hr/datoteka/740473.KM_2.0_HR.pdf
4. Izvor slike 4: Europaska unija (2014.) *Upravljanje znanjem 2.0., Priručnik za poduzeća*, Program za cjeloživotno učenje (Lifelong Learning Programme), str. 58, https://bib.irb.hr/datoteka/740473.KM_2.0_HR.pdf
5. Izvor slike 5: Europaska unija (2014.) *Upravljanje znanjem 2.0., Priručnik za poduzeća*, Program za cjeloživotno učenje (Lifelong Learning Programme), str. 49, https://bib.irb.hr/datoteka/740473.KM_2.0_HR.pdf
6. Izvor slike 6: Europaska unija (2014.) *Upravljanje znanjem 2.0., Priručnik za poduzeća*, Program za cjeloživotno učenje (Lifelong Learning Programme), str. 49, https://bib.irb.hr/datoteka/740473.KM_2.0_HR.pdf
7. Izvor slike 7: Dukić, B. (2013/2014), Kolegij: Baze podataka, Sveučilište Josipa Juraja Strossmayera u Osijeku, Alati poslovne inteligencije, http://www.mathos.unios.hr/~dskrobar/BP_MATHOS_Alati.pdf
8. Izvor slike 8: Tomaš, A. (2014.) Poslovna inteligencija – oblikovanje OLAP kocke na primjeru, Završni rad, Fakultet organizacije i informatike, Varaždin, https://bib.irb.hr/datoteka/718474.1-Anto_Toma_-_Poslovna_inteligencija_oblikovanje_OLAP_kocke_na_primjeru.pdf
9. Izvor slike 9: Mastek (2017): Definition of a Data Warehouse, slide 20, <https://www.slideshare.net/pcherukumalla/date-warehousing-concepts>
10. Izvor slike 10: *Agilna poslovna inteligencija* (2013.), članak, <https://sqlbicro.wordpress.com/tag/poslovna-inteligencija-2/>
11. Izvor slike 11: Tomaš, A. (2014.) Poslovna inteligencija – oblikovanje OLAP kocke na primjeru, Završni rad, Fakultet organizacije i informatike, Varaždin, https://bib.irb.hr/datoteka/718474.1-Anto_Toma_-_Poslovna_inteligencija_oblikovanje_OLAP_kocke_na_primjeru.pdf
12. Izvor slike 12: Vercellis, C. (2009) Business Intelligence: Data Mining and Optimization for Decision Making, John Wiley & Sons Ltd, str. 60
13. Izvor slike 13: Tomaš, A. (2014.) Poslovna inteligencija – oblikovanje OLAP kocke na primjeru, Završni rad, Fakultet organizacije i informatike, Varaždin, https://bib.irb.hr/datoteka/718474.1-Anto_Toma_-_Poslovna_inteligencija_oblikovanje_OLAP_kocke_na_primjeru.pdf
14. Izvor slike 14: Dukić, B. (2013/2014), Kolegij: Baze podataka, Sveučilište Josipa Juraja Strossmayera u Osijeku, Alati poslovne inteligencije, http://www.mathos.unios.hr/~dskrobar/BP_MATHOS_Alati.pdf

15. Izvor slike 15: Tomaš, A. (2014.) Poslovna inteligencija – oblikovanje OLAP kocke na primjeru, Završni rad, Fakultet organizacije i informatike, Varaždin, https://bib.irb.hr/datoteka/718474.1-Anto_Toma_-_Poslovna_inteligencija_oblikovanje_OLAP_kocke_na_primjeru.pdf
16. Izvor slike 16: Market Research SWOT, <http://www.discoveryresearchgroup.com/swot>
17. Izvor slike 17: Zdravstveno veleučilište Zagreb (2008), SWOT ANALIZA, <http://sharepoint.zvu.hr/katedre/318/Nastavni%20matrijali/SWOT-analiza,vježba.pdf>
18. Izvor slike 18: Zdravstveno veleučilište Zagreb (2008), SWOT ANALIZA, <http://sharepoint.zvu.hr/katedre/318/Nastavni%20matrijali/SWOT-analiza,vježba.pdf>
19. Izvor slike 19: Zdravstveno veleučilište Zagreb (2008), SWOT ANALIZA, <http://sharepoint.zvu.hr/katedre/318/Nastavni%20matrijali/SWOT-analiza,vježba.pdf>
20. Izvor slike 20: Zdravstveno veleučilište Zagreb (2008), SWOT ANALIZA, <http://sharepoint.zvu.hr/katedre/318/Nastavni%20matrijali/SWOT-analiza,vježba.pdf>